

Detektion und Verfolgung von Objekten mit lokalen Belegungskarten basierend auf Stereokameradaten

Von der Fakultät für Elektrotechnik, Informationstechnik, Physik
der Technischen Universität Carolo-Wilhelmina zu Braunschweig

zur Erlangung des Grades eines Doktors

der Ingenieurwissenschaften (Dr.-Ing.)

genehmigte Dissertation

von: **Martin Jan Aue**

aus: Lichtenstein

eingereicht am: 06. Januar 2014

mündliche Prüfung am: 30. April 2014

Referenten: Prof. Dr.-Ing. W. Schumacher
Prof. Dr.-Ing. habil. G.-P. Ostermeyer

2014

Veröffentlichungen über den Inhalt der Arbeit sind nur mit schriftlicher Genehmigung der Volkswagen AG zugelassen.

Die Ergebnisse, Meinungen und Schlüsse dieser Dissertation sind nicht notwendigerweise die der Volkswagen AG.

Meinen Töchtern Nora & Matilda

Vorwort

Die vorliegende Arbeit entstand im Kontext des Förderprojekts UR:BAN während meiner Tätigkeit als Doktorand in der Konzernforschung der Volkswagen AG, Abteilung Fahrerassistenz und integrierten Sicherheit. Die Dauer meiner Promotion erstreckte sich über den Zeitraum von Januar 2011 bis Dezember 2013.

Herrn Professor Dr.-Ing. W. Schumacher danke ich für die wissenschaftliche Betreuung meiner Arbeit, dem fachlichen Rat sowie der Freiheit bei der Themenwahl und der Anfertigung meiner Dissertation.

Herrn Professor Dr.-Ing. habil. G.-P. Ostermeyer danke ich für das Interesse an meiner Arbeit und der Übernahme des Koreferats.

Danken möchte ich den Kollegen meiner Abteilung, die mich während meiner Promotion unterstützt haben. Mein besonderer Dank gilt Wojciech Derendarz, der den Grundstein für meine Tätigkeit bei der Volkswagen AG legte, sowie Markus Köchy, der stets ein offenes Ohr zur Problemlösung bei der Umsetzung meiner Arbeit hatte.

Weiterhin möchte ich Sebastian Kranz, Marco Kühnel, Jochen Marx, Michael Schmidt, Eugen Schneider und Thomas Wiedermann danken, die mich vor allem bei der Akquise von Messdaten sowie der Betreuung der Versuchstechnik unterstützten.

Zu großem Dank fühle ich mich Dr. Thorsten Graf verpflichtet, der mich in allen Aspekten als Mentor und Kollege unterstützte und mit wertvollen Diskussionen dem Fortschritt meiner Arbeit beisteuerte. Ebenso gilt mein großer Dank Dr. Jan Effertz und Dr. Matthias Schmid, die mir mit ihren Ideen und inspirierenden Dialogen den Anstoß zu meinem Dissertationsthema gaben.

Ganz besonders danke ich meiner Familie, die mich stets in meinem Promotionsvorhaben unterstützte und motivierte. Allen voran meinen Eltern, die durch ihre Hilfsbereitschaft meine Ausbildung überhaupt ermöglichten.

Von ganzem Herzen danke ich jedoch meiner Frau Stefanie, die mir über schwierige Phasen meines Doktorandendaseins, durch ihren niemals endenden Rückhalt, hinweg verhalf sowie die nötigen Freiräume zur erfolgreichen Fertigstellung meiner Dissertation schaffte.

Braunschweig, im Dezember 2013

Jan Aue

Abstract

The work in hand deals with environment perception of advanced driver assistance systems. Modeling the vehicle environment has been a research topic for years. Among others, it addresses the problem of detecting and tracking objects using data from various onboard vehicle sensors.

In particular, the use of intelligent vehicle in urban environment is very demanding and followed by high requirements. On one hand, it is necessary to react to a large number of objects. On the other hand, the motion and appearance of these objects differs strongly from each other. Therefore, the algorithms of detecting and tracking objects have to be flexible enough to handle the variety of urban obstacles.

Expensive sensor systems are often used to fulfill these requirements. Their accuracy and reliability out performs today's automotive sensors by far. However, they are unsuitable for automotive use due to their construction and high initial costs.

Methods of the present environment perception systems based on data from automotive sensors are modeling road users by means of simple geometries. In many cases, this approach of perceiving vehicle surroundings may be insufficient to fulfill the requirements of highly automated driving. Hence, an improvement of perception methods based on data from automotive sensor is necessary to make progress towards automated driving with advanced driver assistance systems.

This work presents a novel approach of perceiving dynamic objects by combining model based and model free perception methods for object tracking. That concept takes advantages of both methods to improve the tracking process.

The tasks of model based perception approaches mainly consist of creating object hypotheses from sensor raw data as well as stabilizing the object state by means of extended Kalman filtering. The proposed concept is being validated using data from a stereo camera system that suits automotive requirements.

Besides estimating the object state, a detailed and model free description of the object shape is being determined by means of local occupancy grid maps. Measurements that leads to an update of the model based object tracking will be integrated into the dedicated occupancy grid.

That results in a model free and precise object contour containing more information than conventional geometric form models.

The object tracking using local occupancy grid maps improves the Kalman filter based state estimation of objects. Furthermore, this concept shows advantages for integrating incorrect measurements being observed in bad measurement conditions.

Keywords

Stereo camera data - model based and model free environment perception

Kurzfassung

Die vorliegende Arbeit befasst sich mit der Thematik der Umfeldwahrnehmung für fortschrittliche Fahrerassistenzsysteme. Die Modellierung des Fahrzeugumfelds ist seit vielen Jahren Gegenstand der Forschung und adressiert u. a. die Problematik der Detektion und Verfolgung von Umfeldobjekten mittels diverser Sensoren.

Besonders anspruchsvoll ist der Einsatz intelligenter Fahrzeuge in städtischen Verkehrsszenarien, zum einen gilt es auf eine Vielzahl an Objekten zu reagieren, zum anderen setzen deren stark voneinander abweichende Bewegungs- und Erscheinungsformen eine ausreichende Flexibilität der Methodik zur Objektverfolgung voraus.

Um den Anforderungen urbaner Einsatzgebiete gerecht zu werden, erfolgt die Umfelderkennung vielfach mittels kostenintensiver Sensorsysteme. Deren Leistungsfähigkeit übersteigt die der in heutigen Fahrzeugen verbauten Sensoren bei Weitem. Für den derzeitigen Einsatz in fortschrittlichen Fahrerassistenzsystemen sind diese Sensoren aufgrund ihrer baulichen Merkmale sowie der hohen Anschaffungskosten ungeeignet.

Die Methoden der gegenwärtigen Umfeldwahrnehmung, basierend auf fahrzeugtauglicher Sensoren, repräsentieren einzelne Verkehrsteilnehmer meist durch einfache geometrische Modelle. In vielen Fällen ist diese Art der Umfelderkennung für hochautomatisierte Fahrfunktionen fortschrittlicher Fahrerassistenzsysteme unzureichend. Demnach ist eine Verbesserung der Umfeldwahrnehmung, mittels fahrzeugtauglichen Sensoren, notwendig, um einen Fortschritt in Richtung des hochautomatisierten Fahrens durch Fahrerassistenzsysteme zu erzielen.

Der Fokus dieser Arbeit liegt auf der Kopplung modellbasierter mit modellfreien Methoden der Umfeldwahrnehmung. Ziel ist es, die Vorteile beider Methoden für eine verbesserte Objektbeschreibung zu nutzen. Die Aufgaben der modellbasierten Objektverfolgung umfassen das Erstellen von Objekthypothesen aus Sensorrohdaten sowie die zeitliche Stabilisierung der einzelnen Objekteigenschaften. Das vorgestellte Konzept wird anhand von Daten eines Stereokamerasystems validiert.

Neben der Schätzung der Objektzustände erfolgt eine detaillierte modellfreie Beschreibung der Objektkontur durch lokale Belegungskarten. Dabei sind Messungen in die objektspezifische Belegungskarte zu integrieren, die zur Aktualisierung des Objekts in der modellbasierten Objektverfolgung führen. Das Ergebnis stellt einen erhöhten Informationsgehalt der modellfreien Konturbeschreibung der Objekte ggü. konventionellen geometrischen Formmodellen dar.

Die Objektverfolgung mit objektlokalen Belegungskarten wirkt sich positiv auf die modellbasierte Zustandsschätzung der Objekte aus. Darüber hinaus ist dieses Konzept der Objektverfolgung vorteilhaft für die Integration fehlerhafter, durch ungünstige Messbedingungen hervorgerufene, Messungen.

Schlüsselworte

Stereokameradaten - modellbasierte und modellfreie Umfeldwahrnehmung

Inhaltsverzeichnis

Vorwort	vii
Abstract	ix
Kurzfassung	xi
Symbolverzeichnis	xxv
1 Einleitung	1
1.1 Umfeldwahrnehmung intelligenter Fahrzeuge	1
1.2 Motivation	2
1.3 Zielsetzung	3
1.4 Struktur der Arbeit	4
2 Theoretische Grundlagen	7
2.1 Umfoldsensorik der Fahrerassistenz	7
2.1.1 Aktive Sensorik	7
2.1.2 Passive Sensorik	9
2.1.3 Kombinierte Sensorik	10
2.1.4 Gegenüberstellung	11
2.2 Sensorik zur Erfassung der Fahrzeugeigenbewegung	11
2.2.1 Motivation	12
2.2.2 Raddrehzahlsensor	13
2.2.3 Beschleunigungssensor	14
2.2.4 Gierratensensor	15
2.2.5 Inertialplattform	16
2.3 Koordinatensysteme und Transformationen	16
2.3.1 Koordinatensysteme in Bezug auf Fahrerassistenz	16
2.3.2 Homogene Koordinatentransformation	17
2.4 Segmentierung von Sensordaten	18
2.4.1 Überblick der Segmentierungsverfahren	19
2.4.2 Ausgewählte Verfahren	20
2.4.3 Gegenüberstellung	22
2.5 Bayes-Filterung	23
2.5.1 Wahrscheinlichkeitstheorie	23
2.5.2 Bayes'sche Zustandsschätzung	25
2.5.3 Anwendungen Bayes'scher Zustandsschätzung	27
3 Stand der Technik	35
3.1 Aktuelle Forschungsprojekte	35

3.1.1	sim ^{TD}	35
3.1.2	Ko-FAS	36
3.1.3	interactIVe	36
3.1.4	ARTRAC	37
3.1.5	V-Charge	37
3.1.6	UR:BAN	37
3.2	Kartierung und Verfolgung von Umfeldobjekten	38
3.3	Weiterführender Forschungsbedarf	42
4	Modellbasierte Objektbeschreibung und -verfolgung	45
4.1	Motivation	46
4.2	Systemzustand	47
4.3	Bewegungsmodelle	47
4.3.1	Konstante Geschwindigkeit in kartesischen Koordinaten	48
4.3.2	Konstante Beschleunigung in kartesischen Koordinaten	48
4.3.3	Konstante Gierrate und Geschwindigkeit in Polarkoordinaten	49
4.3.4	Konstante Gierrate und Beschleunigung in Polarkoordinaten	49
4.3.5	Zusammenfassung	49
4.4	Kompensation der Eigenbewegung	50
4.5	Formmodelle	50
4.6	Messmodelle	52
4.7	Referenzpunktumschaltung	52
4.8	Multiobjektverfolgung	55
4.8.1	Datenassoziation	55
4.8.2	Suchbereiche	56
4.8.3	Zuordnungsverfahren	57
4.9	Zusammenfassung und Diskussion	58
5	Kartenbasierte Umfeldwahrnehmung	61
5.1	Motivation	61
5.2	Aufbau der Gitterstruktur	61
5.3	Inverses Sensormodell	63
5.4	Schätzung des Belegungszustands mit binärem Bayes-Filter	65
5.5	Kompensation der Eigenbewegung	66
5.6	Zusammenfassung und Diskussion	66
6	Objektverfolgung mittels objektlokaler Belegungskarten	71
6.1	Einleitung	71
6.1.1	Motivation	71
6.1.2	Konzept	71
6.2	Versuchsaufbau	74
6.2.1	Hardwarebeschreibung	74
6.2.2	Schnittstellenbeschreibung	75
6.3	Rohdatenvorverarbeitung	78
6.3.1	Segmentierung	78
6.3.2	Objekthypothesenbildung	81
6.4	Modellbasierte Zustandsschätzung	87

6.4.1	Messmodell	89
6.4.2	Systemzustand	90
6.4.3	Zustandsprädiktion	90
6.4.4	Zustandsaktualisierung	91
6.4.5	Objektverwerfung	91
6.4.6	Objektzusammenführung	91
6.4.7	Relevanzfilterung	92
6.5	Objektlokale Belegungskarten	92
6.5.1	Konzept	92
6.5.2	Kartenverwaltung	94
6.5.3	Registrierung von Sensorrohdaten	95
6.5.4	Zellaktualisierung	97
6.5.5	Konturschätzung	99
6.5.6	Kartenmechanismen	100
6.5.7	Parameterdiskussion	102
6.5.8	Anreicherung der Objekthypothesen mit Karteninformationen	103
7	Validierung	107
7.1	Referenzierung dynamischer Objekte	107
7.2	Verbesserung der modellbasierten Objektverfolgung	108
7.3	Starkes Entfernungsrauschen der Sensorrohdaten	110
7.4	Lückenhafte Objekterfassung	114
7.4.1	Unzureichende Disparitätsberechnung	114
7.4.2	Teilverdeckung der Objekte	117
7.5	Referenzierung der Objektkontur	117
8	Schlussbetrachtung	123
8.1	Zusammenfassung	123
8.2	Ausblick	124
	Literaturverzeichnis	129

Abbildungsverzeichnis

2.1	Objektdarstellung durch unterschiedliche Bezugskoordinatensysteme: Inertialkoordinatensystem K und beschleunigtes Koordinatensystem K'	12
2.2	Übersicht ausgewählter Größen der Fahrzeugdynamikschätzung	13
2.3	Schematischer Aufbau des Raddrehzahlsensors	14
2.4	Funktionsprinzip des Beschleunigungssensors	15
2.5	Aufbau eines mikromechanischen Drehratensensors (Reif (2010))	15
2.6	Koordinatensysteme in Bezug auf ADAS: Fahrzeugkoordinatensystem Fahrzeugkoordinatensystem (FKS), Kamerakoor- dinatensystem (KKS), Laserkoordinatensystem Laserkoordinatensystem (LKS) und Belegungskartenkoordinatensystem Belegungskartenkoordinatensystem (BKS)	17
2.7	Übersicht nicht überlappender Segmentierungsverfahren	19
2.8	Wahrscheinlichkeitsdichtefunktion (PDF) einer Zufallsvariable x für ver- schiedene Erwartungswerte und Varianzen	24
2.9	Graphische Systemdarstellung als Dynamisches Bayes'sches Netz (DBN), in Anlehnung an Murphy (2002)	26
2.10	Ausgewählte Verfahren der Bayes-Filterung, in Anlehnung an Effertz (2009)	27
4.1	Objektverfolgung als graphische Darstellung des Bayes-Netzwerks	45
4.2	Kalman-Filter-Darstellung eines Iterationszyklus am Beispiel einer eindimen- sionalen Wahrscheinlichkeitsverteilung: (1) Ausgehend von der aktuel- len Zustandsschätzung erfolgt die Vorhersage für den nächsten Messzeit- punkt unter Berücksichtigung physikalischer Gesetzmäßigkeiten in Form von Bewegungsmodellen. (2) Diese Modelle stellen eine Näherung gegen- über der tatsächlichen Bewegung dar. Der entstehende Fehler kann durch das Prozessrauschen modelliert und in der Prädiktion berücksichtigt wer- den. (3) Anschließend erfolgt die Aktualisierung der Zustandsschätzung, basierend auf der Differenz zwischen Prädiktion und Messung. In Anleh- nung an Lindl (2009)	46
4.3	Übersicht geometrischer Grundkörper als Konturmodelle am Beispielobjekt Fahrzeug: (a)-Schwerpunkt, (b)-Linie, (c)-Rechteck, (d)-Quader, (e)-Ellipse	51
4.4	Übersicht möglicher Referenzpunkte an einem Objekt: Die Position des lo- kalen Objektkoordinatensystems (rot) ist hierbei mit dem Referenzpunkt (RP) ₅ angegeben. Bezogen auf das Objekt erfolgt die Zuordnung der Refe- renzpunkte mit: 1 - links vorn, 2 - vorn mittig, 3 - rechts vorn, 4 - rechts mittig, 5 - rechts hinten, 6 - hinten mittig, 7 - links hinten, 8 - links mittig, 9 - Objektzentrum, 0 - unbekannt.	53

4.5	Beispielhafte Darstellung der Referenzpunktvergabe zweier Objekte zu den Zeitpunkten t_0 und t_1 : Das Objekt 1 ist uneingeschränkt im Sensorerfassungsbereich sichtbar. Der resultierende RP befindet sich auf der hinteren linken Ecke (RP ₇). Das Objekt 2 stellt ein, in den Sensorsichtbereich einfahrendes, Fahrzeug dar. Der Für die Beobachtung der Objektdynamik ist RP ₃ dem RP ₅ (rot) vorzuziehen, da in diesem Punkt die Bewegung sichtbar ist.	54
4.6	Beispielhafte Darstellung von Prädiktion, Messung und Suchbereichen zur Datenassoziation	56
4.7	Vergleichendes Resultat zweier Zuordnungsverfahren anhand der gleichen Ausgangslage: Der iterative Nearest-Neighbour-Algorithmus ermittelt keine optimale Lösung ($\mathbf{x}_1^* \leftrightarrow \mathbf{y}_1, \mathbf{x}_2^* \leftrightarrow \mathbf{y}_2$) des Assoziationsproblems. In Anlehnung an Stüker (2004)	58
4.8	Ergebnis der modellbasierten Objekterfassung (gelb): (a) - Referenzbild mit Visualisierung der detektierten Objekte, (b) - quaderbasierte Objektdarstellung aus der Vogelperspektive	59
5.1	Gitterstrukturen: (a)-regelmäßige Gitter mit konstanter Raumdichte, (b)-unstrukturiertes Gitter mit variabler Raumdichte	62
5.2	Konzept der 2-D-Belegungskarte	63
5.3	Prinzipiskizze des strahlenbasierten Sensormodells am Beispiel der 2-D Belegungskarte	64
5.4	Aktualisierung des Kartenspeichers aufgrund der Fahrzeugeigenbewegung, in Anlehnung an Nguyen (2012)	67
5.5	Darstellung einer Belegungskarte mit Bereichen dynamischer Objekte: Belegte Zellen sind in rot, freie Zellen in grün und unbekannte Zellen in blau visualisiert. Neben dem Belegungsgitter ist ein dynamisches Objekt mit relativem Geschwindigkeitsvektor in gelb hervorgehoben. Das Referenzbild der Szene ist unten rechts dargestellt.	68
5.6	Effekt der Belegungsinkonsistenz aufgrund dynamischer Objekte: links - sich vom Sensorfahrzeug entfernendes Objekt, rechts - sich dem Sensorfahrzeug näherndes Objekt.	69
5.7	Superposition der Messungen unterschiedlicher Objekte für die Aktualisierung der Belegungsinformation: Das Farbschema der Zellbelegungswahrscheinlichkeit verläuft von Grün (frei) bis hin zu gesättigtem Rot (belegt).	69
6.1	Architektur der Objektverfolgung mittels objektlokaler Belegungskarten	73
6.2	Objektsegmentdarstellung (orange) im 2-D Bildbereich	76
6.3	Objektsegmentdarstellung (orange) im 3-D Raum	77
6.4	Schnittstelle der Stereokamera - Objektsegmente (orange): Die grünen Linien mit blauem Startpunkt der 2-D Darstellung in (a) kennzeichnen den horizontalen Anteil der optischen Flussvektoren des jeweiligen Objektsegments. Für eine bessere Übersicht sind benachbarte Flussvektoren in der Höhe versetzt. Die konstante Objektsegmentbreite beträgt 2 pix bei einer Bildauflösung von $512 \times 256\text{ pix}$	79
6.5	Referenzbild mit Visualisierung der 2-D Objektsegmente (orange)	80

6.6	Segmentierungsergebnis des Streller-Dietmayer (SD)-Verfahrens (3-D Darstellung aus erhöhter Position)	80
6.7	Verbessertes Segmentierungsergebnis des SD-Verfahrens durch die Einführung eines gleitendes Fenster w_{SD} für die Ähnlichkeitssuche (3-D Darstellung aus erhöhter Position)	81
6.8	Objekthypothesenbildung auf Basis einer segmentierten Verkehrsszene: (a) Darstellung in der Bildebene, (b)-(e) Darstellung aus der Vogelperspektive .	82
6.9	Prinzipdarstellung einer Mischverteilung in einem Segment angenähert durch zwei Normalverteilungen (Vogelperspektive)	85
6.10	Vergleich verschiedener Ansätze der Objekthypothesenbildung: Darstellung der Abbildungen (b) - (d) aus der Vogelperspektive	88
6.11	Übersicht der Zustandsaktualisierung \mathbf{x}_k anhand neuer Messungen \mathbf{y}_k . . .	89
6.12	Konzept der objektlokalen Belegungskarte: zugehöriges Objekt (gelb) gibt die Position und Orientierung der Karte vor, belegte Zellen (rot), der Ankerpunkt \mathbf{p}_A kennzeichnet die starre Verbindung zwischen der Karte und dem Objekt	93
6.13	Darstellung der Registrierungsproblematik von Sensorrohdaten \mathbf{y}_n^e (orange) und den zugehörigen lokalen Belegungskarten $K_m^O(z_{i,j})$ (rote Zellen)	95
6.14	Beispielhafte Darstellung der Registrierung eines Segments auf einer objektlokalen Belegungskarte (Vogelperspektive)	96
6.15	Aktualisierung des Zellinhalts der objektlokalen Belegungskarte $K_m^O(z_{i,j})$ anhand neuer Messungen \mathbf{y}_n^e : Für die Anwendung des inversen Sensormodells sind \mathbf{y}_n^e und $\tilde{\mathbf{x}}^p$ von dem Fahrzeug- in das Kamerakoordinatensystem zu überführen.	98
6.16	Gegenüberstellung der Kartenausprägung (rot) des einfachen (a) und des erweiterten (b) Sensormodells zur Integration der Messungen \mathbf{y}_n^e in K_m^O am Beispielobjekt Fahrzeug (Vogelperspektive)	99
6.17	Ergebnis der Objektkonturextraktion in Form der Punktmenge \mathcal{P}^K (grüne 2-D Punkte) auf Basis einer 2-D objektlokalen Belegungskarte (Vogelperspektive)	101
6.18	Gegenüberstellung der Belegungskarte ohne (a) und mit (b) Zentrierung der Objektkontur: Das weiße Quadrat kennzeichnet die äußere Grenze des Belegungsgitters, der gelbe Punkt repräsentiert den Ankerpunkt \mathbf{p}_A , grüne Punkte markieren die Objektkontur \mathcal{P}^K (Vogelperspektive).	102
6.19	Ergebnis der Objektkonturextraktion in Form der Punktmenge \mathcal{P}^K (grüne 2-D Punkte) auf Basis einer 2-D objektlokalen Belegungskarte: Der weiße Rahmen entspricht der Abstraktion von \mathcal{P}^K auf das Rechteckmodell (Vogelperspektive).	104
6.20	Objektlokale Belegungskarte mit Höheninformation für jede Zelle: Die Punktmenge der Objektkontur \mathcal{P}^K ist dargestellt in grün. Der weiße Rahmen entspricht der Abstraktion von \mathcal{P}^K auf das Rechteckmodell. Der gelbe Punkt symbolisiert den Ankerpunkt \mathbf{p}_A des Objekts auf der Belegungskarte (3-D Perspektive).	105
7.1	Prinzipskizze für Referenzierung dynamischer Objekte	108
7.2	Vergleich der Orientierungsschätzung für die Objektverfolgung mit und ohne objektlokaler Belegungskarten (OLK)	109

7.3	Vergleich der Breitenschätzung für die Objektverfolgung mit und ohne OLK	110
7.4	Vergleich der Längenschätzung für die Objektverfolgung mit und ohne OLK	111
7.5	Einfluss einer nassen Fahrbahn auf die Objektverfolgung mittels Stereokameradaten: (a) - Referenzbild mit Visualisierung der Objektsegmente (orange) und horizontalen optischen Flussvektoren (grün), (b) - 3-D Darstellung der segmentierten Objektsegmente (Segmentzugehörigkeit ist durch verschiedene Farben gekennzeichnet), (c) - Objekthypothesenschätzung ohne OLK (in Quaderform), (d) - Objekthypothesenschätzung mit OLK (in Quaderform)	112
7.6	Abweichung der Positionsschätzung der Objektverfolgung von der Referenz in x-Richtung	113
7.7	Lückenhafte Objekterfassung der Objektsegmente (orange) aufgrund von: (a) - homogener Objektstrukturen, (b) - kontrastreichen Lichtverhältnissen und (c) - Sichtbeeinträchtigungen durch Witterungseinflüsse (z. B.: Regentropfen im Kamerabild)	115
7.8	Einfluss fehlender Objektsegmente auf die Objektverfolgung aufgrund von Gegensonne: (a) - Referenzbild mit Visualisierung der Objektsegmente (orange) und horizontalen optischen Flussvektoren (grün), (b) - 3-D Darstellung der segmentierten Objektsegmente (Segmentzugehörigkeit ist durch verschiedene Farben gekennzeichnet), (c) - Objekthypothesenschätzung ohne OLK (in Quaderform), (d) - Objekthypothesenschätzung mit OLK (in Quaderform)	116
7.9	Einfluss der Objektverdeckung auf die Objektverfolgung: (a), (d) - Referenzbild mit Visualisierung der Objektsegmente (orange), (b) - Objekthypothese ohne OLK (in Quaderform), (c) - Objekthypothese mit OLK (in Quaderform), (e) - Objektverfolgung ohne OLK (in Quaderform), (f) - Objektverfolgung mit OLK (in Quaderform)	118
7.10	Vergleich der Objektkonturschätzung auf Basis der modellfreien 2-D Konturpunkte der Menge \mathcal{P}^K sowie dem Rechteckmodell: Die Modellierung des Rechtecks basiert auf \mathcal{P}^K	119
7.11	Abweichungen der modellfreien sowie der modellbasierten Konturschätzung gegenüber der Referenz: Zusätzlich ist die Anzahl der Konturpunkte über die Zeit dargestellt.	120
7.12	Zusammenstellung verschiedener Objekte aus dem Fahrzeugumfeld: Links ist das Referenzbild mit hervorgehobenem Objekt (gelbes Rechteck) dargestellt. Rechts befindet sich die entsprechende Ausprägung der OLK: (a) - Fussgänger, (b) - Motorrad, (c) - Kleinwagen, (d) - Transporter	122
8.1	Verbesserungspotential hinsichtlich der Segmentierungsergebnisse durch objektlokale Belegungskarten (links - Referenzbild mit hervorgehobenem Objekt, rechts - objektlokale Belegungskarte des Objekts mit segmentierten Messungen dargestellt durch verschiedene Farben): (a) - übersegmentiertes Objekt aufgrund unüberbrückbarer Abstände zwischen einzelnen Messungen (3-D Perspektive), (b) - Untersegmentierung aufgrund zu geringer Abstände zwischen den Messungen beider Objekte (3-D Perspektive)	125

8.2	Qualitativer Vergleich der Positionsgenauigkeit von Stereokamera- und Laserscannerdaten: (a) - Referenzbild mit Visualisierung der Objektsegmente, (b) - 3-D Darstellung der Objektsegmente (orange) und Laserscannerdaten (weiß) aus Sicht oberhalb der Sensoren (3-D Perspektive), (c) - 3-D Darstellung der Objektsegmente (orange) und Laserscannerdaten (weiß) von links oben auf das Objekt blickend (3-D Perspektive)	127
-----	--	-----

Tabellenverzeichnis

2.1	Gegenüberstellung ausgewählter Sensortechnologien (In Anlehnung an Stücker (2004); Winner u. a. (2012))	11
2.2	Elementare Transformationen mittels homogener Matrizen	18
2.3	Gegenüberstellung ausgewählter Segmentierungsverfahren	23
6.1	Gegenüberstellung der modell- und kartenbasierten Umfelderkennung	72
6.2	Eigenschaften des eingesetzten Stereokamerasystems	75
6.3	Kriterien der Relevanzfilterung	92

Symbolverzeichnis

Die Schreibweisen und Symbole der vorliegenden Arbeit werde im Folgenden näher erläutert. Im Falle von Mehrdeutigkeiten der Notation oder Symbolik sind diese aus dem Text heraus aufzulösen.

Schreibweisen

Skalare	Kleinbuchstaben	Beispiel: a
Vektoren	Fettgedruckte Kleinbuchstaben	Beispiel: \mathbf{a}
Matrizen	Fettgedruckte Großbuchstaben	Beispiel: \mathbf{A}
Mengen	Kalligrafische Großbuchstaben	Beispiel: \mathcal{A}

Allgemeine mathematische Notationen

\mathbf{a}^T	Transponierter Vektor \mathbf{a}
\mathbf{A}^T	Transponierte Matrix \mathbf{A}
\mathbf{A}^{-1}	Inverse der Matrix \mathbf{A}
$\mathbf{A}^{n \times m}$	Dimension $n \times m$ der Matrix \mathbf{A}
$\exp(\cdot)$	Exponentialfunktion
$\text{diag}(\cdot)$	Diagonalmatrix
$\text{dist}(\mathbf{p})$	Distanz des Punkts \mathbf{p} zum Koordinatenursprung
$\text{dist}(\mathbf{p}_i, \mathbf{p}_j)$	Distanz zwischen den Punkten \mathbf{p}_i und \mathbf{p}_j
$\min(\mathbf{a})$	Minimaler Wert des Vektors \mathbf{a}
$\max(\mathbf{a})$	Maximaler Wert des Vektors \mathbf{a}
$\arg \max_x f(x)$	Wert für x der $f(x)$ maximiert

Abkürzungsverzeichnis

bzw.	beziehungsweise
ca.	circa
d. h.	das heißt
ggü.	gegenüber
u. a.	unter anderem
u. U.	unter Umständen
vgl.	vergleiche
z. B.	zum Beispiel

ADAS	Fortgeschrittene Fahrerassistenzsysteme (Englisch (engl.) Advanced Driver Assistance Systems)
BF	Brute Force
BKS	Belegungskartenkoordinatensystem
bps	Bilder pro Sekunde (engl. Frames per Second)
CA	Konstante Beschleunigung (engl. Constant Acceleration)
CSAA	Konstante Gierwinkel und Beschleunigung (engl. Constant Steering Angle and Acceleration)
CSAV	Konstante Gierwinkel und Geschwindigkeit (engl. Constant Steering Angle and Velocity)
CT	Konstante Gierrate (engl. Constant Turn Rate)
CTRA	Konstante Gierrate und Beschleunigung (engl. Constant Turn Rate and Acceleration)
CTRV	Konstante Gierrate und Geschwindigkeit (engl. Constant Turn Rate and Velocity)
CV	Konstante Geschwindigkeit (engl. Constant Velocity)
DATMO	Detektion und Verfolgung bewegter Objekte (engl. Detection and Tracking of Moving Objects)
DBN	Dynamisches Bayes'sches Netz (engl. Dynamic Bayesian Network)
DGPS	Differential Global Positioning System
EKF	Erweitertes Kalman-Filter (engl. Extended Kalman-Filter)
EM	Expectation Maximization
engl.	Englisch
ESP	Elektronisches Stabilitätsprogramm
FKS	Fahrzeugkoordinatensystem
GBS	Gridbasierte Segmentierung (engl. Grid Based Segmentation)
GPDAF	Generalized Probabilistic Data Association Filter
HMM	Verstecktes Markov Modell (engl. Hidden Markov Model)
ICP	Iterative Closest Point
IMM	Interacting Multiple Model
IMU	Inertialplattform (engl. Inertial Measurement Unit)
JPDAF	Joint Probabilistic Data Association Filter
KKS	Kamerakoordinatensystem
LKS	Laserkoordinatensystem

OLK	Objektlokale Belegungskarten
PDAF	Probabilistic Data Association Filter
PDF	Wahrscheinlichkeitsdichtefunktion (engl. Probability Density Function)
pix	Pixel
RP	Referenzpunkt
SD	Streller-Dietmayer
SIR	Sequential Importance Resampling
SIS	Sequential Importance Sampling
SLAM	Simultaneous Localization and Mapping
WLAN	Wireless Local Area Network

Konventionen

a	Beschleunigung
b	Breite
b_l	Basisbreite
c	Lichtgeschwindigkeit
$disp$	Disparität
Δx_K	Zellgröße in x-Richtung
Δy_K	Zellgröße in y-Richtung
\vec{e}	Einheitsvektor
f	Zustandsübergangsfunktion
f_b	Brennweite
f_d	Frequenzverschiebung
g	Messfunktion
h	Höhe
id	Identifikationsnummer
i_l	Impulsezähler des linken Rads
i_r	Impulsezähler des rechten Rads
K	Zweidimensionale Belegungskarte
l	Länge
logit	Logarithmisches Quotenverhältnis (engl. Log-Odds-Ratio)

Konventionen

l_s	Spurweite
\tilde{M}	Anzahl der Sensormessungen
M^x	Anzahl der Partikel
N	Anzahl der Objekte
\tilde{N}	Tatsächliche Anzahl der Objekte
$\mathcal{N}(\mu, \sigma^2)$	Normalverteilung mit Mittelwert μ und Varianz σ^2
N^e	Maximale Anzahl der Objektsegmente pro Stereomessung
N^R	Anzahl der Impulse pro Radumdrehung
\mathcal{O}	Rechenkomplexität
OCC	Belegt
K^O	Objektlokale Belegungskarte
\vec{r}'	Ortsvektor im bewegten Koordinatensystem
\vec{r}	Ortsvektor im Inertialkoordinatensystem
\mathbf{p}	Punkt im kartesischen Koordinatensystem
$\Delta\psi$	Gierwinkeldifferenz
$\dot{\psi}$	Gierrate
$\ddot{\psi}$	Zeitliche Änderung der Gierrate
\mathbf{p}_A	Ankerpunkt
r	Radialer Abstand
\dot{r}	Radialgeschwindigkeit
\bar{s}	Strecke
$\Delta\bar{s}$	Streckendifferenz
\mathcal{S}	Segment
s_{th}	Entfernungsabhängiger Schwellwert
t	Zeit
Δt	Zeitdifferenz
u_l	Radumfang des linken Rads
u_r	Radumfang des rechten Rads
v	Geschwindigkeit
Δv	Geschwindigkeitsdifferenz
w	Gewicht
$\vec{\omega}$	Winkelgeschwindigkeit
w_{SD}	Gleitendes Fenster
\mathbf{x}^p	Objektpose

\mathbf{y}^o	Objektsegment
\mathbf{y}^O	Quaderhypothese mit Orientierung
z	Zelle einer Belegungskarte

Griechische Buchstaben

Δ	Differenz
η	Normierungsfaktor
γ	Verhältnis der Eigenwerte λ
κ	Anzahl der Aktualisierungen
λ_w	Wellenlänge
μ	Mittelwert
ν	Gewicht einer Messung
ψ	Gierwinkel
ϵ_τ	Verfallswert
σ	Standardabweichung
τ	Gewichtungsfaktor (engl. prior)
θ	Parameterset
v	Vertrauensmaß
ς	Positionsunsicherheit
χ	Partikel
ξ	Hebelarm
ζ	Hebelfaktor

Matrizen und Vektoren

$\mathbf{0}$	Nullvektor
\mathbf{A}	Assoziationsmatrix

Mengen

B	Steuerungsmatrix
d	Dimensionsvektor
E	Einheitsmatrix
F	Zustandsübergangsmatrix
G	Messmatrix
K	Kalmanverstärkungsmatrix
λ	Vektor der Eigenwerte
M	Homogene Matrix
P	Prozesskovarianzmatrix
Q	Kovarianzmatrix des Prozessrauschens
R	Kovarianzmatrix des Messrauschens
S	Kovarianzmatrix der Innovation
s	Segmentschwerpunkt
Σ	Kovarianzmatrix
t	Verschiebungsvektor
u	Steuerungsvektor
v	Messrauschen
w	Prozessrauschen
x	Systemzustand
\mathbf{x}^λ	Eigenvektor
$\bar{\mathbf{y}}$	Innovation
y	Messung

Mengen

\mathcal{K}	Menge aller objektlokalen Belegungskarten
\mathbb{N}	Menge der natürlichen Zahlen

\mathcal{P}^K	Menge aller Konturpunkte
\mathbb{R}	Menge der reellen Zahlen
\mathcal{T}	Menge aller Objekte
\mathcal{T}^*	Nach Relevanzkriterien gefilterte Objektmenge
\mathcal{W}	Menge aller Gewichte
\mathcal{X}	Menge aller Partikel
\mathcal{Y}	Menge aller Objektsegmente
\mathcal{Z}_K	Menge aller Zellen

Kapitel 1

Einleitung

Kapitel 1 leitet in die Thematik der vorliegenden Arbeit ein. Es beschreibt die Motivation sowie die Herausforderungen der Verfolgung von Objekten des Fahrzeugumfelds. Darüber hinaus wird neben der grundlegenden Idee ebenfalls der wissenschaftliche Beitrag dieser Dissertationsschrift erläutert. Eine Übersicht zur Struktur dieser Arbeit schließt das Kapitel ab.

1.1 Umfeldwahrnehmung intelligenter Fahrzeuge

Der Einsatz intelligenter Fahrzeugsysteme für die Anwendung *teilautomatisierter* und *hochautomatisierter* Fahrfunktionen nimmt stetig zu. Neben der anfänglichen militärischen Nutzung sind diese Systeme heutzutage in den Bereichen des Automobils, des öffentlichen Transportwesens sowie für industrielle Anwendungen weit verbreitet. Diese besitzen ein hohes Potential zur signifikanten Steigerung der Verkehrssicherheit sowie der Wirtschaftlichkeit einzelner Transportmittel Bishop (2000). Hierfür kommen zur Erfassung und sinnvollen Interpretation des Umfelds Sensoren in Kombination mit komplexen Algorithmen in intelligenten Fahrzeugen zum Tragen. Dieser Sachverhalt wird im Folgenden auch als *Umfeldwahrnehmung* bezeichnet.

Der Einsatz fortgeschrittener Fahrerassistenzsysteme (ADAS) befähigt das herkömmliche Automobil, den Fahrer in gefährlichen Verkehrssituationen zu warnen oder aktiv in die Fahrzeugführung einzugreifen. Neben der Erhöhung der Verkehrssicherheit verfolgen ADAS das Ziel, den Fahrkomfort und die Effizienz der Fahrzeuge zu steigern. Beispiele für die Markteinführung anfänglicher ADAS sind die automatische Abstandsregelung, der Spurhalteassistent sowie der Parkassistent ADAC (2013). Diese Systeme unterstützen den Fahrzeugführer in einfachen Regelungsaufgaben.

Neuartige ADAS adressieren wesentlich aufwendigere Fahraufgaben. Vom automatischen Parken bis hin zum pilotierten Fahren in Stau-Szenarien übernehmen diese Systeme die Fahrzeugführung Vollmer (2012). Dies verdeutlicht den Übergang von anfänglichen Assistenzsystemen hin zu teilautomatischen Fahrfunktionen für definierte Verkehrsszenarien. Für die Fortführung dieses Trends ist in den kommenden Jahren eine Markteinführung komplexerer Assistenzfunktionen hinsichtlich des hochautomatisierten Fahrens zu erwarten.

Eine der größten Herausforderungen für die Entwicklung zukünftiger ADAS ist die Umfeldwahrnehmung. In Hinblick auf das hochautomatisierte Fahren lassen sich die Aufgaben

der Umfeldwahrnehmung in das Erfassen infrastruktureller Verkehrsmerkmale¹ und die Detektion sowie Verfolgung dynamischer Objekte unterteilen.

Die vorliegende Arbeit befasst sich mit dem Themenkomplex der Verfolgung bewegter Umfeldobjekte mittels ADAS. Die Umfeldwahrnehmung von teil- und hochautomatisierten Fahrzeugen verfolgt das Ziel, ein umfassendes Verständnis über andere Verkehrsteilnehmer anhand von Sensordaten zu erlangen.

Die für die Erfassung der Umfeldobjekte eingesetzten Sensortechnologien unterscheiden sich prinzipiell in aktive und passive Sensoren (siehe Kapitel 2.1). Die aktive Sensorik, beispielsweise Radar² oder Lidar³, misst die Entfernung zu Objekten durch das Aussenden eines aktiven Signals. Dementgegen erfolgt die Objekterfassung mittels passiver Sensoren anhand eines zweidimensionalen Abbilds der Umgebung, ohne Verwendung zusätzlicher Energiequellen.

Die Mehrzahl der sich im Fahrzeugumfeld befindlichen Objekte sind Fußgänger, Radfahrer sowie diverse Fahrzeuge. Diese gilt es möglichst exakt mit Hilfe der Sensordaten zu erfassen und zu beschreiben.

1.2 Motivation

Die Modellierung des Fahrzeugumfelds ist seit vielen Jahren Gegenstand der Forschung. Diverse Förderprojekte (siehe Kapitel 3.1) adressieren die Problematik der Detektion und Verfolgung von Umfeldobjekten anhand verschiedener Sensoren. Neben der Anwendung in überschaubaren Verkehrsszenarien gibt es Bestrebungen, die Umfeldwahrnehmung in urbanen und somit komplexeren Gebieten zu beherrschen Rauskolb u. a. (2008); Urmson u. a. (2008).

Städtische Verkehrsszenarien stellen hohe Anforderungen an die Erfassung und Modellierung des Umfelds intelligenter Fahrzeuge. Einerseits sind diese Systeme gezwungen, auf eine Vielzahl an Objekten zu reagieren. Andererseits setzen deren stark voneinander abweichende Bewegungs- und Erscheinungsformen eine ausreichende Flexibilität der Methodik zur Objektverfolgung voraus. Um den Anforderungen urbaner Einsatzgebiete gerecht zu werden, erfolgt die Umfelderkennung meist mittels kostenintensiver Sensorsysteme⁴ Thrun (2010); Moosmann (2013). Deren Leistungsfähigkeit übersteigt die der in heutigen Fahrzeugen verbauten Sensoren bei Weitem. Für den derzeitigen Einsatz in ADAS sind diese Sensoren aufgrund ihrer baulichen Merkmale sowie der hohen Anschaffungskosten undenkbar.

Die Methoden der gegenwärtigen Umfeldwahrnehmung, basierend auf fahrzeugtauglichen Sensoren, repräsentieren einzelne Verkehrsteilnehmer meist durch einfache geometrische Modelle. Hierbei erfolgt die Modellierung der Objekte als Punkt, Rechteck oder in Quaderform. Diese Art der Objekterfassung stellt eine starke Abstraktion von der menschlichen Wahrnehmung dar und liefert in vielen Fällen unzureichende Informationen über das Fahrzeugumfeld. Die Realisierung hochautomatisierter Fahrfunktionen ist dementsprechend begrenzt.

¹bzw. stationäre Hindernisse

²engl. RADAR - Radio Detection and Ranging

³engl. LiDAR - Light Detection and Ranging

⁴mehr-ebenen Laserscanner z. B.: Velodyne

Anstelle des Ersetzens von kostengünstigen durch leistungsfähigere, jedoch kostenintensive, Sensoren gilt es, die Algorithmen zum Erstellen des Umfeldmodells für die Anwendungen von ADAS zu verbessern.

1.3 Zielsetzung

Die vorliegende Arbeit trägt zur Steigerung der Leistungsfähigkeit der Umfeldmodellierung mit fahrzeugtauglichen Sensoren und somit zum Fortschritt des hochautomatisierten Fahrens mit ADAS bei. Die Verbesserung des Umfeldmodells basiert auf einer neuartigen Kombination modellbehafteter und modellfreier Methoden der Objekterfassung und -verfolgung.

Die Beiträge dieser Arbeit sind:

- die Einführung einer kombinierten Objektverfolgung basierend auf den Methoden der Kalman-Filterung sowie dem Einsatz objektlokaler Belegungskarten. Die grundlegende Idee ist die Verwaltung einer eigenständigen Belegungskarte für jedes Objekt. Weiterhin sind all jene Sensormessungen in der lokalen Belegungskarte zu akkumulieren, die zur Aktualisierung des jeweiligen Objekts in der modellbasierten Objektverfolgung führen.
- die Steigerung des Informationsgehalts ggü. konventionellen Methoden der Modellierung dynamischer Objekte. Der Einsatz objektlokaler Belegungskarten ermöglicht eine detaillierte Beschreibung der Objektkontur. Hieraus resultiert eine Erhöhung des Informationsgehalts der Objektkonturschätzung ggü. stark abstrahierten geometrischen Formmodellen.
- die Verbesserung der modellbasierten Zustandsschätzung. Unter Verwendung der lokalen Karteninformation lässt sich die Objektzustandsschätzung der erweiterten Kalman-Filterung verbessern.
- der Umgang mit stark verrauschten Daten eines fahrzeugtauglichen Sensors. Unter erschwerten Messbedingungen sind hiervon u. a. die Genauigkeit sowie die Zuverlässigkeit der Sensordaten betroffen. Für ein Stereokamerasystem wirken sich beispielsweise kontrastreiche Lichtverhältnisse sowie ungünstige Witterungseinflüsse⁵ negativ aus.

Weiterhin präsentiert diese Arbeit eine qualitative sowie quantitative Bewertung der angeführten Beiträge (siehe oben) für die Objektverfolgung mit objektlokalen Belegungskarten. Unter Einhaltung der Echtzeitanforderung basieren die Ergebnisse der zuverlässigen Objektverfolgung auf Daten eines fahrzeugfähigen Stereokamerasystems.

⁵z. B.: Regen und Nebel

1.4 Struktur der Arbeit

Beginnend mit den theoretischen Grundlagen bis hin zur Validierung der Kombination modellbasierter mit modellfreien Methoden der Umfeldwahrnehmung bauen die Kapitel der vorliegenden Arbeit aufeinander auf.

Kapitel 2 erläutert die theoretischen Grundlagen dieser Arbeit. Neben der Sensorik zum Erfassen des Fahrzeugumfelds (Kapitel 2.1) und der Fahrzeugeigenbewegung (Kapitel 2.2), werden verschiedene Segmentierungsverfahren (Kapitel 2.4) sowie Grundlagen und Anwendungsgebiete der Bayes'schen Filterung (Kapitel 2.5) vorgestellt.

Kapitel 3 fasst den Stand der Technik zusammen und beinhaltet eine Auflistung aktueller Förderprojekte (Kapitel 3.1) sowie die Diskussion relevanter Arbeiten im Bereich der kombinierten Umfeldwahrnehmung zur Kartierung und Verfolgung von Objekten (Kapitel 3.2). Darauf aufbauend wird der weiterführende Forschungsbedarf aufgezeigt (Kapitel 3.3).

Kapitel 4 beschreibt die modellbasierte Objekterfassung und -verfolgung. Neben allgemeinen Bewegungs- und Formmodellen (Kapitel 4.3 und 4.5) erfolgt die Einführung der Referenzpunktumschaltung (Kapitel 4.7). Diese entkoppelt die Abhängigkeit der Objektdynamikschätzung von einer fehlerbehafteten Schätzung der Objektform. Kapitel 4.8 fasst Problemstellungen der Verfolgung mehrerer Objekte zusammen. Weiterhin werden in diesem Kapitel Lösungsansätze zur Datenassoziation sowie verschiedene Zuordnungsverfahren vorgestellt.

Kapitel 5 befasst sich mit dem Aufbau und der Anwendung der kartenbasierten Umfeldwahrnehmung (Kapitel 5.2). Kapitel 5.3 und 5.4 erläutern die Integration einzelner Messungen für die Aktualisierung des 2-D Belegungskitters.

Kapitel 6 stellt die erweiterten Methoden der modellbasierten Objektverfolgung mittels objektlokaler Belegungskarten vor. Hierbei beschreibt Kapitel 6.1 das Konzept des hybriden Verfahrens der Umfeldwahrnehmung. Kapitel 6.2 erläutert den, dieser Arbeit zugrunde liegenden, Versuchsaufbau. Dies beinhaltet u. a. die Schnittstellenbeschreibung der Messdaten des verwendeten Stereokamerasystems. Kapitel 6.3 widmet sich der Rohdatenvorverarbeitung. Kapitel 6.4 beschreibt die auf der Kalman-Filterung basierende Objektverfolgung. Es umfasst die Formulierung des Zustands- und Messmodells sowie die Verwaltung der Objekte. Kapitel 6.5 stellt neben dem Aufbau und der Handhabung objektlokaler Belegungskarten eine modellfreie Konturschätzung der Objekte vor. Darüber hinaus wird deren Nutzen für eine verbesserte Beschreibung der Objekthypothesen aufgezeigt.

Kapitel 7 untersucht die Verbesserung des Umfeldmodells durch die Anwendung objektlokaler Belegungskarten. Hierbei liegt der Fokus auf dem Umgang mit stark verrauschten Sensordaten (Kapitel 7.3) sowie der lückenhaften Objekterfassung (Kapitel 7.4). Des Weiteren erfolgt die Referenzierung der modellfreien Objektkontur.

Kapitel 8 fasst die vorliegende Arbeit zusammen und gibt einen Ausblick auf potentielle Anknüpfungspunkte für die Verbesserung der Objektverfolgung mittels objektlokaler Belegungskarten.

Kapitel 2

Theoretische Grundlagen

Dieses Kapitel bietet einen theoretischen Einstieg in die auf Sensordaten basierende Umfeldmodellierung und trägt zum grundlegenden Verständnis der vorliegenden Arbeit bei. Zu Beginn wird ein Überblick der im Fahrzeug eingesetzten Umfoldsensoren gegeben (siehe Kapitel 2.1). Kapitel 2.3 erläutert notwendige Koordinatensysteme und Transformationen für die Integration von Sensordaten in das Umfeldmodell. Es folgt eine Einführung in diverse Verfahren der Rohdatensegmentierung (siehe Kapitel 2.4). Anschließend werden die Grundlagen und Anwendungen der Bayes'schen Zustandsfilterung (siehe Kapitel 2.5) näher erläutert.

2.1 Umfoldsensorik der Fahrerassistenz

Die Umfeldwahrnehmung ist ein wichtiger Bestandteil von ADAS. Diese stützt sich auf Messungen der am Fahrzeug verbauten Sensoren. Für die im Automobilbereich eingesetzte Umfoldsensorik lassen sich im wesentlichen die Technologien der aktiven und passiven Sensorik (siehe Kapitel 2.1.1, Kapitel 2.1.2) anführen. Die kombinierte Sensorik (siehe Kapitel 2.1.3) beinhaltet Elemente beider Technologien und ist derzeit Gegenstand der Forschung. Anhand ausgewählter Kriterien nimmt Kapitel 2.1.4 eine Gegenüberstellung der angeführten Sensoren vor.

2.1.1 Aktive Sensorik

Zwei für ADAS bedeutende Vertreter aktiver Sensorik sind im Folgenden näher beschrieben.

Radar

Die Technologie des Radars stammt aus der Militärtechnik Mitte des 20. Jahrhunderts. Der Einsatz in Serienfahrzeugen begann Ende der 90. Jahre mit der Einführung der adaptiven Geschwindigkeitsregelanlage¹. Radarsysteme lassen sich entsprechend ihres Frequenzbereichs in Fern- (77 GHz) und Nahbereichsrare (24 GHz) unterscheiden. Radarsensoren sind aktive Sensoren, die emittierte elektromagnetische Wellen aussenden. Das Signal folgt

¹engl.: ACC - Adaptive Cruise Control

meist einer keulenförmigen Ausbreitung und wird an Objekten teilweise reflektiert. Die reflektierte Welle wird über einen Empfänger detektiert und anschließend in Abhängigkeit des verwendeten Verfahrens bezüglich ihrer Laufzeit, Amplitude und Frequenz ausgewertet. Das Reflexionsverhalten ist besonders durch die Leitfähigkeit der Objektoberfläche geprägt. Bedingt durch die Messkeule und eine hohe Strahlaufweitung bieten Radare lediglich eine Winkelauflösung im Gradbereich. Entsprechend der Modulation des Signals lassen sich Radarsysteme in Puls- und Dauerstrichradare unterscheiden. Winner (2012)

Pulsradar Das Pulsradar sendet kurze Signale mit einer festen Trägerfrequenz aus und erfasst mögliche Objektreflexionen in diskreten Zeitabschnitten. Aus der Laufzeit t ergibt sich die Entfernung r des Reflexionsobjekts unter der Berücksichtigung der Lichtgeschwindigkeit c zu:

$$r = \frac{c \cdot t}{2}. \quad (2.1)$$

Aus der Frequenzverschiebung f_d und der Wellenlänge λ_w des Sendesignals ergibt sich die relative Objektgeschwindigkeit \dot{r} zu:

$$\dot{r} = \frac{f_d \cdot \lambda_w}{2}. \quad (2.2)$$

Eine Winkelschätzung kann durch die Verwendung mehrerer Empfangsantennen erfolgen. Durch die unterschiedlichen Laufzeiten des Sendesignals und der bekannten Positionen der Empfangsantennen lässt sich auf die Winkellage des reflektierten Objekts schließen.

Dauerstrichradar Entgegen dem Messprinzip des Pulsradars sendet und empfängt das Dauerstrichradar² ein kontinuierliches Signal. Hierbei ändert sich die Frequenz meist linear³. Analog zum Pulsradar ergibt sich aus der Phasenlage und der Frequenzverschiebung des Sende- und Empfangssignals die Entfernung und Geschwindigkeit des reflektierten Objekts. Durch die längere Zielbeleuchtungszeit erweist sich das Dauerstrichradar robuster gegenüber Rauscheinflüssen als das Pulsradar.

Aufgrund der direkten Messung von Radialgeschwindigkeiten eignen sich Radare besonders gut, um auf den Dynamikzustand detektierter Objekte zu schließen. Weiterhin sind diese weitestgehend unempfindlich gegen Umwelteinflüsse, wie beispielsweise Regen oder Nebel. Stüker (2004); Munz (2011)

Lidar

Die Sensorik des Lidar weist deutliche Parallelen zur Radartechnik auf Hancock u. a. (1999). Das Sendesignal basiert jedoch auf einem gebündeltem Lichtstrahl. Einerseits lässt sich ein Laufzeitverfahren nach Gleichung (2.1) über den Laserpuls⁴ realisieren. Andererseits ist die Messung der Relativgeschwindigkeit über die Differenz zwischen Doppler- und

²engl. CW - Continuous Wave

³engl. LFM - Linear Frequency Modulated Waveform

⁴engl. Laser - Light Amplification by Stimulated Emission of Radiation

Sendefrequenz lediglich mit hohem messtechnischen Aufwand bestimmbar und findet somit keine Anwendung im Automobilbereich. Die Mehrheit der Lidarsensoren ist mehrzielfähig, sodass sich mehrere Reflexionen eines Lichtimpulses detektieren lassen. Aufgrund der starken Fokussierbarkeit des Lichtstrahls ist eine genaue Vermessung von Objektkonturen, mit einer Winkelauflösung deutlich unter einem Grad, möglich. Ungünstige Witterungsverhältnisse, wie beispielsweise Nebel, Regen oder Schnee, nehmen großen Einfluss auf die Qualität der optischen Messung. Prinzipiell lassen sich Lidarsensoren nach dem Abtastverhalten ihrer Umgebung in nicht bewegliche und scannende Sensoren unterscheiden. Geduld (2012)

Nicht bewegliche Lidarsensoren Diese Ausprägung enthält mehrere Sende- und Empfangseinheiten, die einen konstanten Bereich abdecken und in Form von einem Array angeordnet sind. Aufgrund der nicht beweglichen Mechanik gelten diese Sensoren als besonders robust.

Laserscanner Im Allgemeinen nutzen Laserscanner eine bewegliche Mechanik, um den Erfassungsbereich gegenüber den nicht beweglichen Lidarsensoren zu erweitern. Dies lässt sich prinzipiell über zwei Varianten realisieren. Zum einen über eine bewegliche Optik, welche die Lichtimpulse der Sendediode über einen schwenkbaren Spiegel ablenkt, zum anderen über das Rotieren der Sende- und Empfangseinheit. Damit lässt sich ein Erfassungsbereich von bis zu 360° abdecken. Die bewegliche Mechanik wirkt sich in Bezug auf die Robustheit der Messungen nachteilig aus und bietet Potential für zusätzliche Fehlerquellen.

2.1.2 Passive Sensorik

Bildgebende Sensoren haben sich bereits im Automobil etabliert. Diese sind für ADAS von besonderem Interesse, da große Teile der Infrastruktur auf das menschliche Sehen ausgelegt sind. Sie zählen zu den passiven Sensoren und tragen zur Unterstützung des Fahrzeugführers in verschiedensten Verkehrssituationen bei. Als Beispiele lassen sich der Spurhalteassistent⁵, die Anzeige der Rückfahrkamera sowie die Projektion des Fahrzeugumfelds aus der Vogelperspektive⁶ anführen.

Mono

Monokulare Kamerasysteme bilden das Sensorsichtfeld als zweidimensionale Textur ab. Hierbei sind sowohl Grau- als auch Farbinformationen detektierbar. Der Erfassungsbereich ist durch die verwendete Chipfläche der CCD⁷/CMOS⁸-Sensoren sowie der vorgeschalteten Optik definiert. Die Brennweite des Objektivs wirkt sich direkt auf den Öffnungswinkel und die Erfassungsreichweite aus. Prinzipiell gilt es zwischen einem großen Öffnungswinkel

⁵engl. Lane Assist

⁶engl. Top View System

⁷Charge Coupled Device

⁸Complementary Metal Oxide Semiconductor

und einer hohen Auflösung in der Entfernung abzuwägen.

Das zweidimensionale Abbild der erfassten Umgebung bietet einen hohen Informationsgehalt. Oftmals sind die zu detektierenden Merkmale nicht direkt messbar und können unter Verwendung rechenintensiver Verarbeitungsalgorithmen aus dem Bild extrahiert werden. Für detaillierte Ausführungen sei auf Jähne (2005) verwiesen. Im Kontext der ADAS sind u. a. folgende Merkmale von Interesse:

- Verkehrsteilnehmer aller Art (z. B.: Fussgänger, Radfahrer, Pkw)
- Fahrspurmarkierungen
- Verkehrszeichen
- Lichtsignale

Über komplexere Verfahren ist es möglich, eine 3-D-Rekonstruktion der Umgebung durchzuführen. Dies setzt eine geschätzte⁹ oder bekannte¹⁰ Bewegung zwischen verschiedenen Perspektiven einer Szene voraus. Hartley und Zisserman (2000)

Stereo

Das Stereokamerasystem besteht aus zwei Kameras, deren räumliche Lage zueinander bekannt ist. Zusätzlich überlappt ein Großteil der jeweiligen Bildbereiche. Die Basisbreite b_l kennzeichnet die räumliche Distanz zwischen beiden Bildsensoren. Auf zeitlich synchron aufgenommenen Bilddaten ergeben sich Bildpunktkorrespondenzen. Anhand der Verschiebung der Pixelkoordinaten¹¹ $disp$ zwischen dem Bild der ersten Kamera und dem Bild der zweiten Kamera sowie der Basisbreite und der Brennweite f_b ergibt sich die Entfernung r einzelner Bildpunkte zu:

$$r = \frac{b_l \cdot f_b}{disp}. \quad (2.3)$$

Die Qualität der 3-D-Rekonstruktion ist im Wesentlichen durch Fehler in der Korrespondenzanalyse sowie durch die Basisbreite bestimmt. Gleichung (2.3) verdeutlicht den nicht-linearen Einfluss des Disparitätsrauschens auf das Entfernungsrauschen. Grundsätzlich führt eine Erhöhung der Basisbreite zu einem geringeren Entfernungsfehler. Hartley und Zisserman (2003)

2.1.3 Kombinierte Sensorik

Eine Kombination aus Distanz- und bildbasierter Sensorik stellt die 3-D-Kamera dar. Diese erfasst die Textur der Objekte und liefert zeitgleich eine Abstandsmessung in jedem Pixel. Die Distanzmessung ist in Form eines Laufzeitverfahrens realisiert, ähnlich zu den vorgestellten Methoden in Kapitel 2.1.1.

Vertreter dieser Technologie sind beispielsweise der Photomischdetektor¹² (Möller u. a.

⁹engl. SaM - Structure and Motion

¹⁰engl. SfM - Structure from Motion

¹¹Disparität

¹²engl. PMD - Photonic Mixer Device

(2005)) sowie die 3-D Flash Lidar Kamera (Aue u. a. (2011)).

2.1.4 Gegenüberstellung

Tabelle 2.1 fasst für ADAS relevante Merkmale der vorgestellten Sensoren zusammen. Hierbei bezieht sich die Ausrichtung aller Sensoren auf die Fahrtrichtung des Sensorfahrzeugs. Objektspezifische Attribute sind auf Fahrzeuge in paralleler Fahrt zu interpretieren. Die Bewertung aller Merkmale erfolgt in Hinblick auf Einzelmessungen ohne die Berücksichtigung einer zeitlichen Filterung.

Tabelle 2.1: Gegenüberstellung ausgewählter Sensortechnologien (In Anlehnung an Stüker (2004); Winner u. a. (2012))

Sensor	Radar	Lidar	Mono	Stereo
Reichweite	+	+	o*	-*
Öffnungswinkel	o	+	+	o
Objektstand	+	+	n.m. ¹³	o
Objektgeschwindigkeit	+	-	n.m.	n.m.
Objektbreite	-	+	o	+
Objektlänge	n.m.	+	n.m.	o**
Objekthöhe	n.m.	+	o	+
Fahrbahnerkennung	n.m.	-	+	+
Verkehrszeichenerkennung	n.m.	n.m.	+	+
Umwelteinflüsse	+	o	-	-

'+' positiv, 'o' neutral, '-' negativ

*Die Reichweite ist über unterschiedliche Objektive konfigurierbar. Dieses Beispiel bezieht sich auf handelsübliche Kamerasensoren.

**Abhängig vom Aspektwinkel

Zusätzlich zu den angeführten Attributen lassen sich über Bildverarbeitungsalgorithmen weiterführende Merkmale extrahieren. Dazu zählen beispielsweise der Zustand des Fahrtrichtungsanzeigers sowie die Bremsleuchten von Fahrzeugen.

Der Tabelle ist zu entnehmen, dass jeder Sensor spezifische Stärken und Schwächen aufweist. Erst durch die Kombination mehrerer Sensoren lässt sich ein gesamtheitliches Abbild der Fahrzeugumgebung schaffen.

2.2 Sensorik zur Erfassung der Fahrzeugeigenbewegung

Die Bestimmung der Fahrzeugeigenbewegung¹⁴ ist für viele ADAS eine notwendige Voraussetzung, um Applikationen zu realisieren.

¹³n.m. - nicht messbar

¹⁴bezeichnet im Kontext der Umfelderkennung die Bewegung des Sensorfahrzeugs (Egobewegung)




Abbildung 2.1: Objektdarstellung durch unterschiedliche Bezugskordinatensysteme: Inertialkoordinatensystem K und beschleunigtes Koordinatensystem K'

2.2.1 Motivation

Umfeldsensoren bestimmen die jeweiligen Messgrößen (z. B.: Position und/oder Geschwindigkeit) stets relativ. Das bedeutet, dass diese Messgrößen eine Überlagerung aus der Objektposition/-bewegung mit der Egoposition/-bewegung darstellen. Diese Überlagerung äußert sich in Form zusätzlicher, an dem gemessenen Objekt angreifenden, Trägheitskräfte¹⁵, der Zentrifugal- und der Corioliskraft. Abbildung 2.1 verdeutlicht das Prinzip dieser Überlagerung. Ausgehend von einem Inertialkoordinatensystem K lässt sich die Position eines Objekts durch den Ortsvektor \vec{r} beschreiben. Das Inertialsystem bezeichnet dabei ein von Scheinkräften freies System, in dem alle an einem Objekt angreifenden Kräfte beobachtbar sind. Dementgegen unterliegen Objekte in dem beschleunigten Koordinatensystem K' Scheinkräften, die sich auf die Positionsmessung des Objekts \vec{r}' aufprägen.

Demnach ergibt sich für ein mit $\vec{\omega}$ rotierendes Koordinatensystem K' die Beschleunigung des Objekts zu:

$$\ddot{\vec{r}}' = \ddot{\vec{r}} - \underbrace{2 \left(\vec{\omega} \times \dot{\vec{r}}' \right)}_{a_c} - \underbrace{\vec{\omega} \times \left(\vec{\omega} \times \vec{r}' \right)}_{a_z}, \quad (2.4)$$

wobei a_c und a_z die Beschleunigungen, hervorgerufen durch die Coriolis- sowie die Zentrifugalkraft, darstellen. Scheck (2003)

Um rechenintensive und komplizierte Objektmodellierungen für die Verfolgung von Objekten zu vermeiden, sind alle Messgrößen der Umfeldsensoren um die Fahrzeugeigenbewegung zu bereinigen. Die dafür benötigten Größen sind beispielsweise die Geschwindigkeit v sowie die Beschleunigung a , der Gierwinkel ψ oder etwa die Gierrate¹⁶ $\dot{\psi}$ des Sensorfahrzeugs. Abbildung 2.2 stellt ausgewählte Größen grafisch dar.

Durch die Bereinigung der Fahrzeugeigenbewegungen lässt sich das Bezugskordinatensystem als Inertialsystem betrachten, das frei von Scheinkräften und somit frei von Scheinbeschleunigungen a_c und a_z ist. Damit vereinfacht sich die Dynamikmodellierung (siehe

¹⁵auch als Scheinkräfte bezeichnet

¹⁶Drehgeschwindigkeit um die Fahrzeughochachse




Abbildung 2.2: Übersicht ausgewählter Größen der Fahrzeugdynamikschätzung

Kapitel 4.3) für die Verfolgung der Objekte. Im Folgenden werden verschiedene Sensoren für die Schätzung der Fahrzeugeigenbewegung vorgestellt.

2.2.2 Raddrehzahlsensor

Die Messung der Raddrehzahl erlaubt die Schätzung der Radgeschwindigkeit, -beschleunigung sowie Drehrichtung. Raddrehzahlsensoren sind heutzutage meist aktive Sensoren, welche mittels Hallprinzip die Radbewegung messen. Der schematische Aufbau ist in Abbildung 2.3 dargestellt. Der Polring ist in gleichgroße Sektoren unterteilt und muss mit dem zu messenden Rad starr verbunden sein. Dabei besitzen benachbarte Sektoren jeweils eine unterschiedliche Magnetisierung¹⁷. Mit Hilfe des Sensorelements ist es möglich, den Übergang der Sektoren¹⁸ in Form des ausgewiesenen Signalverlaufs (siehe Abbildung 2.3) zu erfassen. Hierdurch lässt sich auf die zurückgelegte Raddrehung schließen. Für weiterführende Informationen wird auf Reif (2010) verwiesen.

Sind beispielsweise die Hinterräder eines Fahrzeugs mit Drehzahlsensoren ausgestattet, ist die Schätzung der zurückgelegten Strecke \bar{s} , v , a , ψ und $\dot{\psi}$, unter Verwendung zusätzlicher Informationen, möglich. Diese Zusatzinformationen umfassen die Messung der Zeit t durch einen Zeitgeber, die Anzahl der linken bzw. der rechten Radimpulse i_l und i_r , die Gesamtanzahl möglicher Radimpulse N^R , die Spurweite l_s sowie die Radumfänge u_l bzw. u_r des linken und rechten Hinterrads. Anhand dieser Größen lassen sich $\Delta\bar{s}$ und $\Delta\psi$

¹⁷ gekennzeichnet durch N-Nordpol und S-Südpol

¹⁸ in diesem Zusammenhang auch als Radimpuls bezeichnet




Abbildung 2.3: Schematischer Aufbau des Raddrehzahlsensors

mit:

$$\Delta \bar{s} = \frac{1}{2} \left(\frac{i_r}{N^R} u_r + \frac{i_l}{N^R} u_l \right) \quad \text{und} \quad \Delta \psi = \arctan \left[\frac{1}{l_s} \left(\frac{i_r}{N^R} u_r - \frac{i_l}{N^R} u_l \right) \right] \quad (2.5)$$

berechnen. Durch die Berücksichtigung der Zeitspanne Δt zwischen unterschiedlichen Messungen ergeben sich die Größen v , a und $\dot{\psi}$ zu:

$$v = \frac{\Delta \bar{s}}{\Delta t}, \quad a = \frac{\Delta v}{\Delta t} \quad \text{und} \quad \dot{\psi} = \frac{\Delta \psi}{\Delta t}. \quad (2.6)$$

Mit Hilfe des Gierwinkels ψ lassen sich v und a in ihre Einzelkomponenten bezüglich der Koordinatenachsen zerlegen. Die Genauigkeit der ermittelbaren Eigenbewegung ist stark abhängig von der vorherrschenden Fahrdynamik. Ein an den Rädern auftretender Schlupf sowie ein möglicher Schwimmwinkel bei dynamischer Fahrweise sind in diesem Modell nicht berücksichtigt und verfälschen somit das Ergebnis der Eigenbewegungsschätzung. Demnach eignet sich die Bewegungsschätzung auf Grundlage des Raddrehzahlsensors lediglich für Fahrmanöver mit geringfügigen Beschleunigungen.

2.2.3 Beschleunigungssensor

Der Beschleunigungssensor eignet sich, um hohe Fahrdynamik in Form von moderaten Beschleunigungen entlang der Fahrzeugachsen (siehe Abbildung 2.2) zu detektieren. Die zeitliche Integration der Beschleunigungswerte ermöglicht die von Schlupf oder einem auftretenden Schwimmwinkel einflussfreie Bestimmung der Geschwindigkeitsänderung. Abbildung 2.4 stellt das Funktionsprinzip eines mikromechanischen Beschleunigungssensors dar. Dieser besteht aus zwei Kapazitäten und einer zwischen den Kondensatorplatten aufgehängten seismischen Masse. Durch ruckartige Bewegungen verändert sich der Abstand der seismischen Masse zu den Kondensatorplatten und bewirkt eine kapazitive Änderung, welche eine Bestimmung der Beschleunigung erlaubt. Weiterführende Informationen beinhaltet Reif (2010).

Die Bestimmung von v bzw. \bar{s} ist durch eine zeitliche Integration von a möglich. Dabei wird jedoch der Messfehler von a integriert, wodurch die Genauigkeit der geschätzten Größen stark reduziert wird. Der Beschleunigungssensor eignet sich demnach für die Schätzung der Fahrzeugeigenbewegung auf Basis des Raddrehzahlsensors als zusätzlicher Sensor zum Erfassen von starken Beschleunigungen.




Abbildung 2.4: Funktionsprinzip des Beschleunigungssensors




Abbildung 2.5: Aufbau eines mikromechanischen Drehratensensors (Reif (2010))

2.2.4 Gierratensensor

Ebenso wie die Beschleunigung ist die Gierrate $\dot{\psi}$ in dynamisch anspruchsvollen Fahrsituationen nur unzureichend mit Hilfe des Raddrehzahlsensors bestimmbar. Um $\dot{\psi}$ zu messen, kann alternativ ein mikromechanischer Drehratensensor zur Messung der Drehgeschwindigkeit um die Fahrzeughochachse eingesetzt werden.

Die Funktionsweise des Gierratensensors ist in Abbildung 2.5 grafisch dargestellt. Ein Aktor versetzt eine seismische Masse in eine oszillierende Schwingung. Durch eine Drehbewegung wirkt die Corioliskraft auf die seismische Masse in Form einer Kippbewegung und beeinflusst somit die Schwingungsrichtung. Die Amplitude der Kippbewegung ist proportional zur Drehrate und lässt sich kapazitiv detektieren. Darüber hinaus gehende Informationen zu Drehratensensoren finden sich in Reif (2010).

In heutigen Fahrzeugen eingesetzte Beschleunigungs- und Gierratensensoren sind für die Detektion hoher Amplituden ausgelegt und werden oftmals für Arbeiten nahe des fahrphysikalischen Grenzbereichs, wie beispielsweise für die Funktionalität des elektronischen Stabilitätsprogramms (ESP), genutzt. Dadurch ist die Messgenauigkeit von geringen Beschleunigungen bzw. geringen Gierraten mit hohen Messfehlern behaftet und muss dementsprechend für die Schätzung der Fahrzeugeigenbewegung berücksichtigt werden.

2.2.5 Inertialplattform

Die Inertialplattform (IMU) fusioniert Messungen hochwertiger Beschleunigungs- und Drehratensensoren zur Schätzung einer Relativbewegung entlang der drei Raumachsen. Das Fehlermaß der Schätzung ist dabei entsprechend der qualitativ hochwertigen Sensorik gering. Zusätzlich sind einige IMUs in der Lage, eine globale Referenzierung durch die Integration von Satelliten- und Korrekturdaten zu bewerkstelligen. Dies ermöglicht eine globale Positionierung mit einer Fehlergenauigkeit bis in den einstelligen Zentimeterbereich, wodurch die Eigenbewegungsschätzung erheblich vereinfacht wird. Verfügt die Einheit über mehrere Empfangsantennen, ist die Ausrichtung des Sensorfahrzeugs sowie der Schwimmwinkel mit geringem Aufwand ermittelbar.

Trotz präziser Positions- und Dynamikschätzung sind hochgenaue IMUs aufgrund hoher Anschaffungskosten derzeit nicht für eine serientaugliche Fahrzeugeigenbewegungsschätzung im Bereich der ADAS geeignet. Ihre Anwendung beschränkt sich vorwiegend auf den Forschungs- und Entwicklungsbereich zur Referenzierung anderer Messsysteme. Eskandarian (2012)

2.3 Koordinatensysteme und Transformationen

Für die Auswertung von Messdaten verschiedener Sensoren ist das Verständnis über Koordinatensysteme und Transformationen zwischen unterschiedlichen Bezugspunkten essentiell. Das Kapitel 2.3.1 gibt einen Überblick der für ADAS relevanten Koordinatensysteme. Anschließend legt Kapitel 2.3.2 die Transformationsvorschrift für das Umrechnen von Koordinaten zwischen unterschiedlichen Bezugspunkten dar.

2.3.1 Koordinatensysteme in Bezug auf Fahrerassistenz

Wie bereits in Kapitel 2.1.4 angeführt, ist für die Erfassung des gesamten Fahrzeugumfelds der Einsatz mehrerer Sensoren notwendig. Abbildung 2.6 stellt in Bezug auf ADAS typische Koordinatensysteme unterschiedlich am Fahrzeug verbauter Sensoren dar.

Fahrzeugkoordinatensystem

Der Ursprung des rechtshändigen Fahrzeugkoordinatensystems befindet sich nach *DIN 70000* mittig auf der Fahrzeughinterachse. Die x-Koordinate ist entlang der Fahrzeuglängsachse ausgerichtet. Die Höhe des Koordinatensystems ist hierbei nicht vorgegeben und wird meist auf die Fahrbahn projiziert.




Abbildung 2.6: Koordinatensysteme in Bezug auf ADAS: Fahrzeugkoordinatensystem FKS, Kamerakordinatensystem KKS, Laserkordinatensystem LKS und Belegungskartenkoordinatensystem BKS

Sensorkoordinatensystem

Die Messungen verschiedener Sensoren werden jeweils in deren sensor-spezifischem Koordinatensystem beschrieben. In Abbildung 2.6 sind hierfür das Kamera- sowie das Laserkordinatensystem zu nennen. Der Ursprung befindet sich in der Regel mittig auf der jeweiligen Sendeeinheit.

Belegungskartenkoordinatensystem

Das Belegungskartenkoordinatensystem beschreibt die Anordnung der Zellen einer mehrdimensionalen Gitterstruktur. Die Position und Orientierung entspricht der Anfangspose des Fahrzeugs.

2.3.2 Homogene Koordinatentransformation

Die homogene Koordinatentransformation hat ihren Ursprung in der projektiven Geometrie Hartley und Zisserman (2003). Sie beschreibt die Transformation einer Koordinate zwischen unterschiedlichen Bezugspunkten unter Verwendung einer Matrixmultiplikation. Das Abbilden kartesischer Koordinaten der Dimension 3×1 zu homogenen Koordinaten (Dimension 4×1) erfolgt durch:

Tabelle 2.2: Elementare Transformationen mittels homogener Matrizen

Art	Matrix	Freiheitsgrad
Projektive Abbildung	$\begin{bmatrix} \mathbf{A} & \mathbf{t} \\ \mathbf{v}^T & 1 \end{bmatrix}$	15
Euklidische Abbildung	$\begin{bmatrix} \mathbf{R} & \mathbf{t} \\ \mathbf{0}^T & 1 \end{bmatrix}$	6
Rotation	$\begin{bmatrix} \mathbf{R} & \mathbf{0} \\ \mathbf{0}^T & 1 \end{bmatrix}$	3
Translation	$\begin{bmatrix} \mathbf{0} & \mathbf{t} \\ \mathbf{0}^T & 1 \end{bmatrix}$	3
Skalierung	$\begin{bmatrix} \mathbf{S} & \mathbf{0} \\ \mathbf{0}^T & 1 \end{bmatrix}$	3

$$\mathbf{p} = (x, y, z)^T = (x, y, z, 1)^T. \quad (2.7)$$

Das Abbilden eines Punkts \mathbf{p} aus dem Koordinatensystem K in das Koordinatensystem K' wird durch die Multiplikation mit einer homogenen Matrix \mathbf{M} realisiert zu:

$$\mathbf{p}'_{4 \times 1} = \mathbf{M}_{4 \times 4} \cdot \mathbf{p}_{4 \times 1}, \quad (2.8)$$

wobei der vierte Parameter einen globalen Skalierungsfaktor darstellt.

Elementare Transformationen für \mathbf{M} sind der Tabelle 2.2 zu entnehmen. \mathbf{A} bezeichnet hierbei eine 3×3 Matrix, \mathbf{R} eine 3-D Rotationsmatrix, \mathbf{t} einen 3-D Translationsvektor, \mathbf{v} einen 3-D Vektor, $\mathbf{0}$ einen 3-D Nullvektor und \mathbf{S} eine 3-D Diagonalmatrix.

Ein Beispiel für die Anwendung der euklidischen Transformation ist das Umrechnen von Messdaten aus dem Laserkoordinatensystem in das Fahrzeugkoordinatensystem (siehe Abbildung 2.6). Die homogene Transformationsmatrix ist aus sechs Freiheitsgraden zu bestimmen: den Rotationen ($\mathbf{R}_x, \mathbf{R}_y, \mathbf{R}_z$)¹⁹ sowie den Translationen (t_x, t_y, t_z)²⁰.

2.4 Segmentierung von Sensordaten

Die Segmentierung von Sensordaten ist ein fundamentaler Verarbeitungsschritt für die Detektion und Verfolgung von Objekten. Mit Hilfe unterschiedlicher Verfahren werden Messungen anhand ihrer Ähnlichkeit bezüglich ausgewählter Eigenschaften gruppiert. Im folgenden stellt Kapitel 2.4.1 unterschiedliche Verfahren der Segmentierung vor. Anschließend legt Kapitel 2.4.2 die Funktionsweise ausgewählter Segmentierungsverfahren dar. Kapitel 2.4.3 fasst die Segmentierungsverfahren in einer Gegenüberstellung zusammen.

¹⁹Rotation um die jeweilige Koordinatenachse

²⁰Translation entlang der jeweiligen Koordinatenachse

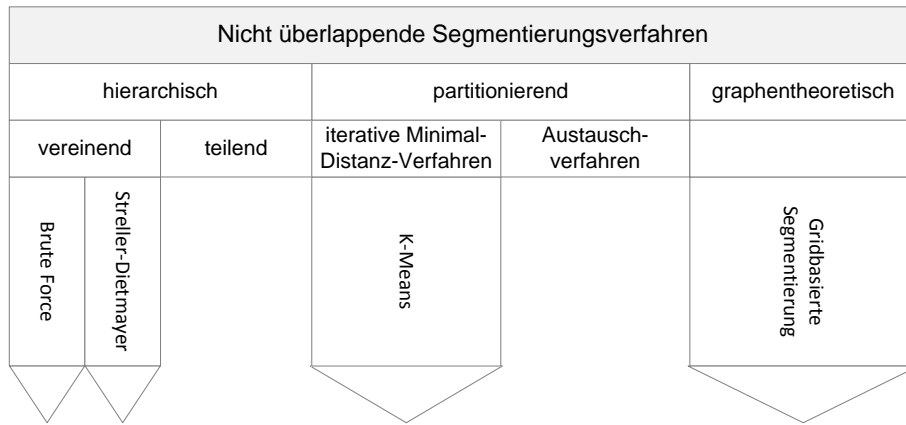


Abbildung 2.7: Übersicht nicht überlappender Segmentierungsverfahren

2.4.1 Überblick der Segmentierungsverfahren

Gemäß der Definitionen 2.1 und 2.2 lassen sich Segmentierungsverfahren in überlappende und nicht überlappende Verfahren unterteilen.

Definition 2.1. Sei \mathcal{Y} die Menge aller Messungen y_1, \dots, y_m , dann ist eine überlappende Segmentierung gleichzusetzen mit der Unterteilung von \mathcal{Y} in n Teilmengen s_1, \dots, s_n für die gilt: $\bigcup_{i=1}^n s_i = \mathcal{Y}$ mit $s_i \cap s_j \neq \emptyset \quad \wedge \quad i \neq j$.

Definition 2.2. Sei \mathcal{Y} die Menge aller Messungen y_1, \dots, y_m , dann ist eine nicht überlappende Segmentierung gleichzusetzen mit der Unterteilung von \mathcal{Y} in n Teilmengen s_1, \dots, s_n für die gilt: $\bigcup_{i=1}^n s_i = \mathcal{Y}$ mit $s_i \cap s_j = \emptyset \quad \wedge \quad i \neq j$.

Verfahren nach Definition 2.2 werden im Folgenden näher erläutert und lassen sich nach Abbildung 2.7 in verschiedene Kategorien einordnen.

Die nicht überlappenden Segmentierungsverfahren sind in *hierarchische*, *partitionierende* und *graphentheoretische Verfahren* unterteilbar. Hierarchische Verfahren segmentieren ähnliche Elemente aufgrund von Distanzen. Ein Element bezeichnet hierbei eine mehrdimensionale Sensormessung in Form eines Messvektors \mathbf{y} . Diese Verfahren arbeiten *vereinend*, d. h. es erfolgt ein schrittweises Zusammenführen einzelner Segmente²¹ bzw. *teilend*, d. h. es erfolgt ein schrittweises Aufspalten in separate Segmente²².

Entgegen den hierarchischen Segmentierungsverfahren gilt die Segmentanzahl k für partitionierende Verfahren als bekannt. Hierbei erfolgt anhand von *Minimal-Distanz-Verfahren* bzw. der Optimierung eines beliebigen Gütekriteriums²³ über *Austauschverfahren* die iterative Zuordnung aller Messungen zu k Segmenten.

Die graphentheoretischen Verfahren betrachten Segmente als Objekte im mehrdimensionalen Raum. Die Segmentrepräsentation sowie die Segmentbildung basieren hierbei auf der Graphentheorie. Buntine (1994)

²¹beginnend als Einzelsegment für jeden Messvektor

²²beginnend aus einem Segment, welches alle Messvektoren umfasst

²³z. B.: das Varianzkriterium

2.4.2 Ausgewählte Verfahren

Aus den unterschiedlichen Anforderungen an die Segmentierung von Daten geht eine Vielzahl von Segmentierungsverfahren aus der Literatur hervor. Mit Hinblick auf die Einsetzbarkeit im Bereich der ADAS werden im Folgenden ausgewählte Segmentierungsalgorithmen näher beschrieben.

Brute Force

Der Brute Force (BF) Algorithmus ist ein vereinendes Verfahren. Der Algorithmus berechnet eine vollständige Distanzmatrix²⁴, die eine Bestimmung des Nachbarn mit dem geringsten Abstand ermöglicht. Die prinzipielle Funktionsweise lässt sich in zwei Arbeitsschritte unterteilen:

- Aufbau der Distanzmatrix
- Zusammenführen von Messvektoren

Der erste Verarbeitungsschritt bestimmt die Distanz zwischen allen Messvektoren²⁵ der zu segmentierenden Datenmenge \mathcal{Y} zu:

$$\text{dist}(\mathbf{y}_i, \mathbf{y}_j) = \sqrt{(\mathbf{y}_i - \mathbf{y}_j)^T \cdot \mathbf{M} \cdot (\mathbf{y}_i - \mathbf{y}_j)}. \quad (2.9)$$

Die Matrix \mathbf{M} gewichtet die einzelnen Merkmale der Messvektoren. Entsprechen die Gewichte einer Gleichverteilung in Form der Einheitsmatrix \mathbf{E} , beschreibt die Distanz den euklidischen Abstand zweier Messvektoren mit:

$$\text{dist}(\mathbf{y}_i, \mathbf{y}_j) = \sqrt{(\mathbf{y}_i - \mathbf{y}_j)^T \cdot \mathbf{E} \cdot (\mathbf{y}_i - \mathbf{y}_j)}. \quad (2.10)$$

Das Zusammenführen von Messvektoren zu Segmenten basiert auf der berechneten Distanzmatrix. Für jeden Messvektor werden zugehörige Nachbarn ermittelt²⁶ und zu einem Segment gruppiert.

Streller-Dietmayer

Der SD Ansatz nach Streller und Dietmayer (2002) beschreibt die effiziente Segmentierung einer geordneten Datenstruktur distanzbasierter Sensorik, wie beispielsweise den Messungen eines Laserscanners. Die Gruppierung benachbarter Messpunkte erfolgt anhand der Distanz zueinander sowie einem entfernungsabhängigen Schwellwert s_{th} . Die Distanzberechnung zweier Messvektoren ergibt sich zu:

$$\text{dist}(r_{m_i}, r_{m_{i+1}}) = \sqrt{r_{m_i}^2 + r_{m_{i+1}}^2 - 2r_{m_i}r_{m_{i+1}} \cos(\Delta\alpha)}. \quad (2.11)$$

²⁴Distanzberechnung zwischen allen Messvektoren

²⁵Spaltenvektoren

²⁶abhängig von dem maximal zulässigen Abstand

Der Parameter r_{m_i} kennzeichnet den radialen Abstand der Messung im Sensorkoordinatensystem und $\Delta\alpha$ die Winkelauflösung des Sensors.

Der adaptive Schwellwert berechnet sich gemäß:

$$s_{th}(r_{m_i}, r_{m_{i+1}}) = s_0 + s_1 \min\{r_{m_i}, r_{m_{i+1}}\}. \quad (2.12)$$

Die Konstante s_0 dient der Rauschunterdrückung der Entfernungsmessung im Sensor-Nahbereich. Der untere Grenzwert des linearen Koeffizienten s_1 wird bestimmt zu:

$$s_{1,min} = \frac{\text{dist}(r_{m_i}, r_{m_i})}{r_{m_i}} = \sqrt{2 - 2 \cos(\Delta\alpha)} = \text{const.} \quad (2.13)$$

Anhand des Vergleichs der berechneten Distanz nach Gleichung (2.11) zweier Messvektoren sowie des berechneten Schwellwerts nach Gleichung (2.12) erfolgt die Zugehörigkeit gemäß:

$$\begin{aligned} \text{dist}(r_{m_i}, r_{m_{i+1}}) &> s_{th}(r_{m_i}, r_{m_{i+1}}) && \rightarrow \text{trennen,} \\ \text{dist}(r_{m_i}, r_{m_{i+1}}) &\leq s_{th}(r_{m_i}, r_{m_{i+1}}) && \rightarrow \text{gruppieren.} \end{aligned} \quad (2.14)$$

Dichtebasierte Segmentierung

Der dichtebasierte Ansatz beschreibt die effiziente Segmentierung der Messvektoren \mathbf{y}_i einer ungeordneten Datenmenge \mathcal{Y} . Die Segmentbildung erfolgt über die Dichte der Messvektoren im mehrdimensionalen Raum. Bekannte Verfahren sind das DBSCAN²⁷ nach Ester u. a. (1996), OPTICS²⁸ nach Ankerst u. a. (1999) sowie die gridbasierte Segmentierung (GBS) nach Yu und Wong (2006). Im Folgenden wird der Algorithmus GBS näher vorgestellt.

GBS basiert auf der Verwendung einer Gitterstruktur, um lokale Häufungen in verschiedenen Messvektoren zu bestimmen. Die prinzipielle Funktionsweise lässt sich in vier Arbeitsschritten zusammenfassen:

- Aufbau der Gitterstruktur und Extraktion belegter Zellen
- Zellen mit höchster lokaler Kardinalität²⁹ bilden temporäre Schwerpunkte der Segmente \mathbf{s}_j
- Zuordnung der Schwerpunkte \mathbf{s}_j zu jeder Zelle
- Zuordnung aller \mathbf{y}_i jeder Zelle zu dem Segmentschwerpunkt \mathbf{s}_j anhand des geringsten Abstands gemäß Gleichung (2.10)

²⁷engl. Density-Based Spatial Clustering of Applications with Noise

²⁸engl. Ordering Points to Identify the Clustering Structure

²⁹Anzahl der Messvektoren pro Zelle

Mit Hilfe der Gitterstruktur lässt sich die Rechenkomplexität für hohe Datenmengen erheblich reduzieren. Im Gegensatz zum BF-Algorithmus erfolgt die Distanzberechnung pro Messvektor lediglich für eine geringe Anzahl von Segmentschwerpunkten \mathbf{s}_j , anstelle des Vergleichs mit allen Messvektoren \mathbf{y}_i .

K-Means

K-Means nach Lloyd (1982) ist ein partitionierender Segmentierungsalgorithmus mit dem Ergebnis der vollständigen Zuordnung aller Messvektoren \mathbf{y}_i einer Menge \mathcal{Y} zu k Segmenten. Der Algorithmus strebt ein globales Minimum der Zielfunktion J mit:

$$J = \sum_{j=1}^k \sum_{\mathbf{y}_i \in S_j} \|\mathbf{y}_i - \mathbf{s}_j\|^2 \quad (2.15)$$

an, kann jedoch ebenso in lokalen Minima terminieren. Der Ablauf des Algorithmus lässt sich in folgende Verarbeitungsschritte unterteilen:

- Wählen der k Segmentschwerpunkte $\mathbf{s}_1 \dots \mathbf{s}_k$
- Zuordnung aller Messvektoren \mathbf{y}_i zu den Segmentschwerpunkten \mathbf{s}_j anhand $\min \{\text{dist}(\mathbf{y}_i, \mathbf{s}_j)\}$
- Neuberechnung aller Segmentschwerpunkte \mathbf{s}_j
- Erneute Zuordnung der Messvektoren \mathbf{y}_i zu den aktualisierten Segmentschwerpunkten \mathbf{s}_j

Die Menge aller Messvektoren ist nach Gleichung (2.15) vollständig segmentiert, wenn die Segmentschwerpunkte konvergieren.

Bezogen auf die Rechenzeit ist der K-Means Algorithmus sehr effizient. Die Schwierigkeit liegt jedoch in der a-priori-Bestimmung der Segmentanzahl k , die das Ergebnis maßgeblich beeinflusst.

2.4.3 Gegenüberstellung

Tabelle 2.3 bewertet die in Kapitel 2.4.2 angeführten Segmentierungsverfahren. Die gelisteten Kriterien beziehen sich auf die Einsetzbarkeit im Bereich der Umfeldsensorik für ADAS. Die Echtzeitfähigkeit der gesamten Verarbeitungskette stellt dabei eine der wesentlichen Anforderungen dar. Unter Echtzeit nach *DIN 44300* ist die Verarbeitung aller anfallenden Daten innerhalb einer vorgegebenen Zeitspanne zu verstehen, sodass die gesamte Verarbeitungskette ständig verfügbar ist. Für Systeme der Umfeldwahrnehmung muss demnach die Verarbeitungszeit der gesamten Prozesskette unter der Messzykluszeit der verwendeten Sensorik liegen.

Aufgrund der Berechnung einer vollständigen Distanzmatrix erweist sich der BF-Algorithmus als robust gegenüber Fehlmessungen und liefert zu jedem Zeitpunkt ein eindeutiges Segmentierungsergebnis. Zusätzlich lassen sich verschiedene Metriken (siehe Gleichung

Tabelle 2.3: Gegenüberstellung ausgewählter Segmentierungsverfahren

Verfahren	BF	SD	GBS	K-Means
Laufzeitverhalten	-	+	o	+
Kompensation von Fehlmessungen	+	-	-	o
Granularität der Segmente	o	+	+	-
Modularität	+	-	o	o

'+' positiv, 'o' neutral, '-' negativ

(2.9) und (2.10)) zur Abstandsbestimmung einsetzen, wodurch die Modularität erhöht wird. Die Rechenkomplexität $\mathcal{O}(n_m^2)$ des Algorithmus nimmt quadratisch mit der Anzahl an Messvektoren n_m zu. Dies wirkt sich nachteilig auf das Laufzeitverhalten für große Datenmengen \mathcal{Y} aus. Der SD-Algorithmus hingegen zeigt mit $\mathcal{O}(n_m)$ ein geringeres Laufzeitverhalten und verfügt aufgrund des entfernungsabhängigen Schwellwerts s_{th} über eine gute Granularität der Segmente. Das Laufzeitverhalten des K-Means-Algorithmus ist dem des SD gleichgestellt, jedoch hängt dessen Segmentierungsergebnis stark von der a-priori bestimmten Segmentanzahl k ab.

Es wird deutlich, dass keines der dargestellten Segmentierungsverfahren für jedes Segmentierungsproblem eine optimale Lösung bietet. Die Auswahl des Verfahrens ist daher stark von den Anforderungen der zu segmentierenden Messdaten abhängig.

2.5 Bayes-Filterung

In diesem Kapitel werden die Grundlagen für die Zustandsfilterung nach Bayes erläutert. Kapitel 2.5.1 führt notwendige Notationen der Wahrscheinlichkeitstheorie ein. Es folgt eine Darlegung der Zustandsschätzung nach Bayes in Kapitel 2.5.2 sowie ein Überblick verschiedener Anwendungen (siehe Kapitel 2.5.3).

2.5.1 Wahrscheinlichkeitstheorie

Sei X eine Zufallsvariable, die ein Ereignis x annehmen kann, so bezeichnet $p(X = x)$ dessen Wahrscheinlichkeit. Für eine vereinfachte Notation wird $p(X = x)$ im Folgenden mit $p(x)$ abgekürzt. Dabei genügt $p(x)$ der Ungleichung:

$$0 \leq p(x) \leq 1. \quad (2.16)$$

Alle Einzelereignisse summieren sich sowohl für diskrete als auch kontinuierliche Wahrscheinlichkeiten zu eins gemäß:

$$\begin{aligned} \sum_x p(x) &= 1 \\ \int p(x) dx &= 1. \end{aligned} \quad (2.17)$$




Abbildung 2.8: PDF einer Zufallsvariable x für verschiedene Erwartungswerte und Varianzen

Im Besonderen gilt dies für das Ereignis $p(x)$ und dessen Gegenereignis $p(\bar{x})$ mit:

$$p(x) + p(\bar{x}) = 1. \quad (2.18)$$

Die Anwendung von Schätzverfahren erfolgt typischerweise in einem kontinuierlichen Raum. Hier besitzen Zufallsvariablen eine PDF, wie in Abbildung 2.8 beispielhaft dargestellt. Diese zeigt mehrere eindimensionale Normalverteilungen $\mathcal{N}(\mu, \sigma^2)$ mit dem Erwartungswert μ und der Varianz σ^2 :

$$p(x) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left(-\frac{1}{2} \frac{(x - \mu)^2}{\sigma^2}\right). \quad (2.19)$$

Für die mehrdimensionale Normalverteilung $\mathcal{N}_p(\boldsymbol{\mu}, \boldsymbol{\Sigma})$ eines Zufallsvektors $\mathbf{x} = (x_1, \dots, x_p)$ ergibt sich die PDF in vektorieller Form zu:

$$p(\mathbf{x}) = \frac{1}{(2\pi)^{\frac{p}{2}} \det(\boldsymbol{\Sigma})^{\frac{1}{2}}} \exp\left(-\frac{1}{2} (\mathbf{x} - \boldsymbol{\mu})^T \boldsymbol{\Sigma}^{-1} (\mathbf{x} - \boldsymbol{\mu})\right) \quad (2.20)$$

mit dem mehrdimensionalen Erwartungswert $\boldsymbol{\mu}$ und der Kovarianzmatrix $\boldsymbol{\Sigma}$.

Sei Y eine weitere Zufallsvariable, die ein Ereignis y annehmen kann, dann ist die *Verbundwahrscheinlichkeit* von X und Y definiert durch:

$$p(x, y) = p(X = x, Y = y). \quad (2.21)$$

Wenn X und Y unabhängig sind, gilt:

$$p(x, y) = p(x)p(y). \quad (2.22)$$

Sind jedoch X und Y abhängig voneinander, gilt die *bedingte Wahrscheinlichkeit* wie folgt:

$$p(x|y) = p(\text{Ereignis } X = x, \text{ gegeben } Y = y) \quad (2.23)$$

und beschreibt die Wahrscheinlichkeit, dass das Ereignis x eintritt, unter der Bedingung das Ereignis y bereits eingetreten ist.

Das *Bayes-Theorem* (Thrun u. a. (2005)) stellt einen Zusammenhang zwischen $p(x|y)$ und $p(y|x)$ zu:

$$p(x|y) = \frac{p(y|x)p(x)}{p(y)} \quad (2.24)$$

für $p(y) > 0$ her. Der Nenner in Gleichung (2.24) ist unabhängig von x und wird auch als Normierungsfaktor η bezeichnet:

$$p(x|y) = \eta p(y|x)p(x). \quad (2.25)$$

2.5.2 Bayes'sche Zustandsschätzung

Die Bayes'sche Zustandsschätzung, auch Bayes-Filter genannt, ist ein allgemeiner rekursiver Algorithmus, der eine Wahrscheinlichkeitsdichtefunktion (PDF) schätzt. Unter Verwendung des Bayes-Theorems kann die Schätzung eines Systemzustands aus Beobachtungen erfolgen. Die Beobachtung, in Form einer Messung \mathbf{y} , sowie der Systemzustand \mathbf{x} werden durch die Wahrscheinlichkeiten $p(\mathbf{y})$ und $p(\mathbf{x})$ erfasst. Lässt \mathbf{y} einen Rückschluss auf \mathbf{x} zu, dann bezeichnet $p(\mathbf{x})$ die *a-priori* Wahrscheinlichkeit und $p(\mathbf{x}|\mathbf{y})$ die *a-posteriori* Wahrscheinlichkeit. Die Schätzung \mathbf{x} maximiert $p(\mathbf{x}|\mathbf{y})$ und wird als *Maximum a-posteriori*-Schätzung bezeichnet. Dementgegen kennzeichnet $p(\mathbf{y}|\mathbf{x})$ die *Maximum Likelihood*-Schätzung.

Sei ein System gegeben, dass über die Zeit beobachtet und dessen Zustand \mathbf{x}_k geschätzt wird. Der Index k bezieht sich hierbei auf einen diskreten Zeitpunkt. Ziel ist es, die bestmögliche Schätzung für \mathbf{x}_k , unter Berücksichtigung aller Messungen $\mathbf{y}_{1:k}$ sowie aller Steuerungsvektoren³⁰ $\mathbf{u}_{0:k-1}$, zu bestimmen. Die PDF für den Zustandsübergang ergibt sich zu:

$$p(\mathbf{x}_k | \mathbf{x}_{0:k-1}, \mathbf{y}_{1:k-1}, \mathbf{u}_{0:k-1}). \quad (2.26)$$

Weiterhin gilt für die PDF der aktuellen Messung die Berücksichtigung aller Zustände $\mathbf{x}_{0:k}$, vorangegangener Messungen $\mathbf{y}_{1:k-1}$ sowie Steuerungsvektoren $\mathbf{u}_{0:k-1}$:

$$p(\mathbf{y}_k | \mathbf{x}_{0:k}, \mathbf{y}_{1:k-1}, \mathbf{u}_{0:k-1}). \quad (2.27)$$

³⁰Daten aller bekannten Einflussgrößen des Systems




Abbildung 2.9: Graphische Systemdarstellung als DBN, in Anlehnung an Murphy (2002)

Beinhaltet \mathbf{x}_k die Information aller vorangegangenen Zustände $\mathbf{x}_{0:k-1}$, sodass der Folgezustand \mathbf{x}_{k+1} lediglich von \mathbf{x}_k abhängt, wird dieser Prozess als *Markov-Kette* bezeichnet. Gilt weiterhin, dass \mathbf{y}_k lediglich vom aktuellen Zustand \mathbf{x}_k abhängt, so ist das System als DBN nach Abbildung 2.9 darstellbar. Dieses verfügt über Steuerungseingaben $\mathbf{u}_{0:k-1}$, Systemzustände $\mathbf{x}_{0:k}$ sowie Systemausgaben $\mathbf{y}_{1:k}$. Die Verbindungspfeile verweisen auf bedingte Abhängigkeiten zwischen den Knoten³¹ des Graphen. Lässt sich \mathbf{x}_k ausschließlich über \mathbf{y}_k beobachten, kann das System als Verstecktes Markov Modell (HMM), die einfachste Form des DBN, erfasst werden.

Aufgrund der Systemannahmen für DBN vereinfacht sich die PDF nach Gleichung (2.26) zu:

$$p(\mathbf{x}_k | \mathbf{x}_{k-1}, \mathbf{u}_{k-1}) = p(\mathbf{x}_k | \mathbf{x}_{0:k-1}, \mathbf{y}_{1:k-1}, \mathbf{u}_{0:k-1}) \quad (2.28)$$

sowie Gleichung (2.27) zu:

$$p(\mathbf{y}_k | \mathbf{x}_k) = p(\mathbf{y}_k | \mathbf{x}_{0:k}, \mathbf{y}_{1:k-1}, \mathbf{u}_{0:k-1}). \quad (2.29)$$

Die PDF des Zustandsübergangs hängt demnach lediglich von \mathbf{x}_{k-1} und \mathbf{u}_{k-1} sowie die Messung \mathbf{y}_k lediglich von \mathbf{x}_k ab.

Die zu schätzende a-posteriori Verteilungsfunktion des Systemzustands \mathbf{x}_k basiert auf allen Messungen und Steuerungsvektoren zum Zeitpunkt k . Diese lässt sich als bedingte Wahrscheinlichkeit des Zustands, gegeben aller vorangegangenen Messungen und Steuerungsvektoren, modellieren zu:

$$p(\mathbf{x}_k | \mathbf{y}_{1:k}, \mathbf{u}_{0:k-1}). \quad (2.30)$$

Die a-priori PDF beschreibt hingegen die Wahrscheinlichkeit der Zustandsschätzung für \mathbf{x}_k , unter Berücksichtigung aller Messungen und Steuerungsvektoren des vorangegangenen Zeitschritts $k - 1$ mit:

$$p(\mathbf{x}_k | \mathbf{y}_{1:k-1}, \mathbf{u}_{0:k-1}). \quad (2.31)$$

³¹Zustände des graphischen Modells

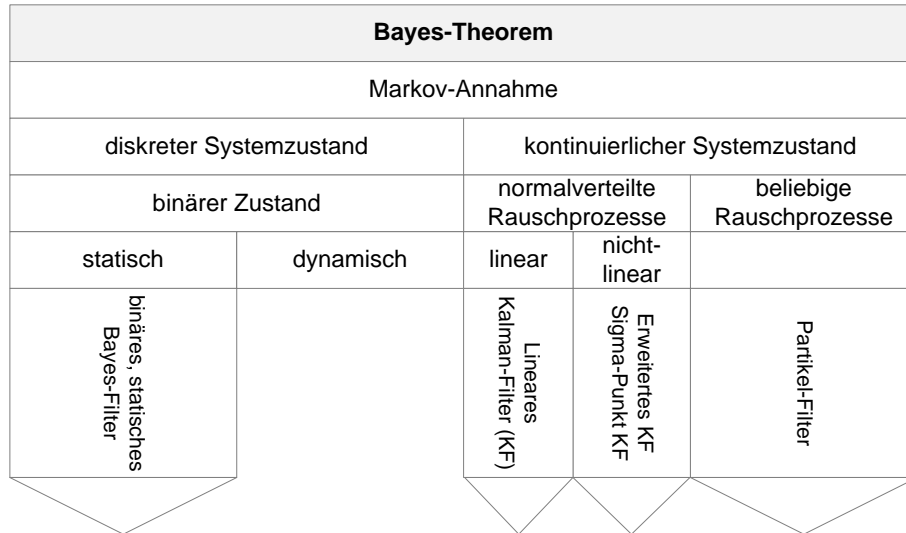


Abbildung 2.10: Ausgewählte Verfahren der Bayes-Filterung, in Anlehnung an Effertz (2009)

Das Bayes-Filter lässt sich prinzipiell in zwei Verarbeitungsschritte, die *Prädiktion* und die *Innovation*, unterteilen. Die Prädiktion entspricht hierbei der a-priori PDF nach Gleichung (2.31) und berechnet sich zu:

$$p(\mathbf{x}_k | \mathbf{y}_{1:k-1}, \mathbf{u}_{0:k-1}) = \int \overbrace{p(\mathbf{x}_k | \mathbf{x}_{k-1}, \mathbf{u}_{k-1})}^{\text{Zustandsübergang}} p(\mathbf{x}_{k-1} | \mathbf{y}_{1:k-1}, \mathbf{u}_{0:k-2}) d\mathbf{x}_{k-1}. \quad (2.32)$$

Die Innovation ist proportional dem Produkt der a-priori Wahrscheinlichkeit sowie der Maximum-Likelihood-Schätzung $p(\mathbf{y}_k | \mathbf{x}_k)$ und berechnet sich gemäß Gleichung (2.30) zu:

$$p(\mathbf{x}_k | \mathbf{y}_{1:k}, \mathbf{u}_{0:k-1}) = \eta \underbrace{p(\mathbf{y}_k | \mathbf{x}_k)}^{\text{Maximum-Likelihood}} \underbrace{p(\mathbf{x}_k | \mathbf{y}_{1:k-1}, \mathbf{u}_{0:k-1})}_{\text{Prädiktion}}. \quad (2.33)$$

2.5.3 Anwendungen Bayes'scher Zustandsschätzung

Das Bayes-Filter bildet die Basis für eine Vielzahl an Schätzalgorithmen. Im Folgenden werden ausgewählte Verfahren näher erläutert. Diese lassen sich anhand der in Abbildung 2.10 dargestellten Eigenschaften unterteilen.

Binäres Bayes-Filter mit statischem Zustand

Das binäre Bayes-Filter mit statischem Zustand findet Anwendung in der modellfreien Umfeldwahrnehmung. Es wird beispielsweise zur Schätzung der Belegungswahrscheinlichkeit von Belegungskarten (Kapitel 5) verwendet. Dabei gilt der binäre Zustand $\mathbf{x} \in \{0, 1\}$ einzelner Kartenelemente als zeitlich konstant.

Es folgt eine Herleitung (angelehnt an Thrun u. a. (2005)) der rekursiven Formulierung des binären Bayes-Filters in der Darstellung des logarithmischen Quotenverhältnisses.

Die Definition des Quotenverhältnisses des Zustands \mathbf{x} lautet:

$$\frac{p(\mathbf{x})}{p(\bar{\mathbf{x}})} = \frac{p(\mathbf{x})}{1 - p(\mathbf{x})}. \quad (2.34)$$

Erweitert um den Logarithmus ergibt sich das logarithmische Quotenverhältnis *logit* zu:

$$\text{logit}(\mathbf{x}) = \log \frac{p(\mathbf{x})}{1 - p(\mathbf{x})}. \quad (2.35)$$

Die Berechnung der Wahrscheinlichkeit $p(\mathbf{x})$ aus dem logarithmischen Quotenverhältnis nach Gleichung (2.35) berechnet sich zu:

$$p(\mathbf{x}) = 1 - \frac{1}{1 + \exp(\text{logit}(\mathbf{x}))}. \quad (2.36)$$

Aufgrund des statischen Verhaltens des Zustands \mathbf{x} , hängt die Schätzung der PDF mit:

$$p(\mathbf{x}_k | \mathbf{y}_{1:k}, \mathbf{u}_{0:k-1}) = p(\mathbf{x} | \mathbf{y}_{1:k}) \quad (2.37)$$

lediglich von vorangegangenen Messungen $\mathbf{y}_{1:k}$ ab. Mittels des Satzes von Bayes (2.24) folgt für Gleichung (2.37):

$$p(\mathbf{x} | \mathbf{y}_{1:k}) = \frac{p(\mathbf{y}_k | \mathbf{x}, \mathbf{y}_{1:k-1}) p(\mathbf{x} | \mathbf{y}_{1:k-1})}{p(\mathbf{y}_k | \mathbf{y}_{1:k-1})}. \quad (2.38)$$

Aus der Annahme heraus, dass die einzelnen Messungen unabhängig voneinander sind, folgt die Abhängigkeit der Messung \mathbf{y}_k vom Zustand \mathbf{x} mit:

$$p(\mathbf{y}_k | \mathbf{x}, \mathbf{y}_{1:k-1}) = p(\mathbf{y}_k | \mathbf{x}). \quad (2.39)$$

Mittels Gleichung (2.39) vereinfacht sich Gleichung (2.38) zu:

$$p(\mathbf{x} | \mathbf{y}_{1:k}) = \frac{p(\mathbf{y}_k | \mathbf{x}) p(\mathbf{x} | \mathbf{y}_{1:k-1})}{p(\mathbf{y}_k | \mathbf{y}_{1:k-1})}. \quad (2.40)$$

Die Anwendung des Bayes-Theorems für die Beobachtung von \mathbf{y}_k aufgrund von \mathbf{x} führt zu:

$$p(\mathbf{y}_k | \mathbf{x}) = \frac{p(\mathbf{x} | \mathbf{y}_k) p(\mathbf{y}_k)}{p(\mathbf{x})}. \quad (2.41)$$

Eingesetzt in Gleichung (2.40) folgt der Ausdruck:

$$p(\mathbf{x} | \mathbf{y}_{1:k}) = \frac{p(\mathbf{x} | \mathbf{y}_k) p(\mathbf{y}_k) p(\mathbf{x} | \mathbf{y}_{1:k-1})}{p(\mathbf{x}) p(\mathbf{y}_k | \mathbf{y}_{1:k-1})}. \quad (2.42)$$

Analog gilt für das Gegenereignis $\bar{\mathbf{x}}$:

$$p(\bar{\mathbf{x}}|\mathbf{y}_{1:k}) = \frac{p(\bar{\mathbf{x}}|\mathbf{y}_k)p(\mathbf{y}_k)p(\bar{\mathbf{x}}|\mathbf{y}_{1:k-1})}{p(\bar{\mathbf{x}})p(\mathbf{y}_k|\mathbf{y}_{1:k-1})}. \quad (2.43)$$

Das Verhältnis von $p(\mathbf{x}|\mathbf{y}_{1:k})$ zu $p(\bar{\mathbf{x}}|\mathbf{y}_{1:k})$ ist demnach definiert durch:

$$\frac{p(\mathbf{x}|\mathbf{y}_{1:k})}{p(\bar{\mathbf{x}}|\mathbf{y}_{1:k})} = \frac{p(\mathbf{x}|\mathbf{y}_k)}{1 - p(\mathbf{x}|\mathbf{y}_k)} \frac{p(\mathbf{x}|\mathbf{y}_{1:k-1})}{1 - p(\mathbf{x}|\mathbf{y}_{1:k-1})} \frac{1 - p(\mathbf{x})}{p(\mathbf{x})}. \quad (2.44)$$

Die Erweiterung auf das logarithmische Quotenverhältnis nach Gleichung (2.35) ergibt:

$$\text{logit}_k(\mathbf{x}) = \log \frac{p(\mathbf{x}|\mathbf{y}_k)}{1 - p(\mathbf{x}|\mathbf{y}_k)} + \overbrace{\log \frac{p(\mathbf{x}|\mathbf{y}_{1:k-1})}{1 - p(\mathbf{x}|\mathbf{y}_{1:k-1})}}^{\text{logit}_{k-1}(\mathbf{x})} + \overbrace{\log \frac{1 - p(\mathbf{x})}{p(\mathbf{x})}}^{\text{logit}_0^{-1}(\mathbf{x})}. \quad (2.45)$$

Dabei bezeichnet $\text{logit}_0(\mathbf{x})$ das initiale und $\text{logit}_{k-1}(\mathbf{x})$ das vorangegangene logarithmische Quotenverhältnis. Somit lautet die finale Darstellung der rekursiven Formulierung des binären Bayes-Filters unter Verwendung des logarithmischen Quotenverhältnisses für den Zeitpunkt k :

$$\text{logit}_k(\mathbf{x}) = \log \frac{p(\mathbf{x}|\mathbf{y}_k)}{1 - p(\mathbf{x}|\mathbf{y}_k)} + \text{logit}_{k-1}(\mathbf{x}) - \text{logit}_0(\mathbf{x}). \quad (2.46)$$

Diese Darstellung bietet den Vorteil der effizienten Aktualisierung von \mathbf{x} durch einfache Additionen.

Kalman-Filter

Das Kalman-Filter nach Kalman u. a. (1960) und Welch und Bishop (1995) ist ein rekursiver Algorithmus zur Zustandsschätzung linearer Systeme. Das Anwendungsgebiet des Filters ist vielfältig und wird u. a. in der Inertialnavigation eingesetzt. Das Kalman-Filter ist ein Bayes-Filter, dessen Schätzung sich auf die Beobachtung und die Modellierung eines Systems stützt. Die Schätzung der a-posteriori PDF (nach Gleichung (2.33)) ergibt sich aus dem geschätzten Zustand \mathbf{x} und der Prozessfehlerkovarianzmatrix \mathbf{P} . Sie beruht auf der Minimierung des quadratischen Fehlers zwischen dem geschätzten und dem wahren Zustand.

Das Prozessmodell in Form der Zustandsübergangsfunktion f_k beschreibt die rekursive Änderung einer zeitdiskreten Systembetrachtung zu:

$$\mathbf{x}_k = f_k(\mathbf{x}_{k-1}, \mathbf{u}_{k-1}, \mathbf{w}_{k-1}) \quad (2.47)$$

mit dem Steuerungsvektor \mathbf{u}_{k-1} , dem Prozessrauschen \mathbf{w}_{k-1} und dem diskreten Zeitindex k . Das Messmodell kennzeichnet den Übergang des Zustands \mathbf{x}_k auf eine Messung \mathbf{y}_k zum

Zeitpunkt k und ist durch die Messfunktion g_k definiert zu:

$$\mathbf{y}_k = g_k(\mathbf{x}_k, \mathbf{v}_k). \quad (2.48)$$

Hierbei bezeichnet \mathbf{v}_k das Messrauschen. Nach Gleichung (2.47) und (2.48) ergeben sich für lineare Systeme mit additivem Rauschen folgende Gleichungen:

$$\mathbf{x}_k = \mathbf{F}_{k-1}\mathbf{x}_{k-1} + \mathbf{B}_{k-1}\mathbf{u}_{k-1} + \mathbf{w}_{k-1} \quad (2.49)$$

$$\mathbf{y}_k = \mathbf{G}_k\mathbf{x}_k + \mathbf{v}_k \quad (2.50)$$

mit der Zustandsübergangsmatrix \mathbf{F}_{k-1} , der Steuerungsmatrix \mathbf{B}_{k-1} und der Messmatrix \mathbf{G}_k .

Der Algorithmus des Kalman-Filters setzt folgende Annahmen voraus:

- die Systemmatrizen \mathbf{F}_k , \mathbf{B}_k und \mathbf{G}_k gelten als bekannt
- eine initiale PDF mit \mathbf{x}_0 und \mathbf{P}_0 ist bekannt
- die Rauschterme der Gleichungen (2.49) und (2.50) gelten als weiß, mittelwertfrei und normalverteilt
- \mathbf{w}_k und \mathbf{v}_k sind unkorreliert

Damit gilt:

$$\mathbf{w}_k \sim \mathcal{N}(0, \mathbf{Q}_k) \quad (2.51)$$

$$\mathbf{v}_k \sim \mathcal{N}(0, \mathbf{R}_k) \quad (2.52)$$

Der Zustand \mathbf{x}_k mit zugehöriger Kovarianzmatrix \mathbf{P}_k zum Zeitpunkt k wird unter Einbeziehung eines neuen Messwerts \mathbf{y}_{k+1} folgendermaßen aktualisiert:

1. Prädiktion des Zustands aus bisherigem Zustand und den Systemmatrizen \mathbf{F}_k und \mathbf{B}_k :

$$\mathbf{x}_{k+1}^* = \mathbf{F}_k\mathbf{x}_k + \mathbf{B}_k\mathbf{u}_k \quad (2.53)$$

Prädiktion der Kovarianzmatrix unter der Berücksichtigung des Prozessrauschens:

$$\mathbf{P}_{k+1}^* = \mathbf{F}_k\mathbf{P}_k\mathbf{F}_k^T + \mathbf{Q}_k \quad (2.54)$$

2. Anhand des prädizierten Zustands und der Messmatrix erfolgt die Messwertprädiktion:

$$\mathbf{y}_{k+1}^* = \mathbf{G}_{k+1}\mathbf{x}_{k+1}^* \quad (2.55)$$

Die Differenz aus der Messwertprädiktion und dem neuen Messwert ergibt die Innovation:

$$\bar{\mathbf{y}}_{k+1} = \mathbf{y}_{k+1} - \mathbf{y}_{k+1}^* \quad (2.56)$$

Aus der Messmatrix, der Zustandskovarianz und der Messunsicherheit resultiert die Innovationskovarianz:

$$\mathbf{S}_{k+1} = \mathbf{G}_{k+1} \mathbf{P}_{k+1}^* \mathbf{G}_{k+1}^T + \mathbf{R}_{k+1} \quad (2.57)$$

3. Die Kalmanverstärkung ist definiert zu:

$$\mathbf{K}_{k+1} = \mathbf{P}_{k+1}^* \mathbf{G}_{k+1}^T \mathbf{S}_{k+1}^{-1} \quad (2.58)$$

Die Aktualisierung des Systemzustands und des zugehörigen Prozessfehlers erfolgt letztendlich zu:

$$\mathbf{x}_{k+1} = \mathbf{x}_{k+1}^* + \mathbf{K}_{k+1} \bar{\mathbf{y}}_{k+1} \quad (2.59)$$

$$\mathbf{P}_{k+1} = (\mathbf{E} - \mathbf{K}_{k+1} \mathbf{G}_{k+1}) \mathbf{P}_{k+1}^* \quad (2.60)$$

Um numerische Probleme der Implementierung für Gleichung (2.60) zu umgehen, beschreiben Verhaegen und Van Dooren (1986) verschiedene Lösungsansätze. Einer der bekanntesten ist die *Joseph-Form* mit folgender Definition:

$$\mathbf{P}_{k+1} = (\mathbf{E} - \mathbf{K}_{k+1} \mathbf{G}_{k+1}) \mathbf{P}_{k+1}^* (\mathbf{E} - \mathbf{K}_{k+1} \mathbf{G}_{k+1})^T + \mathbf{K}_{k+1} \mathbf{G}_{k+1} \mathbf{K}_{k+1}^T. \quad (2.61)$$

Erweitertes Kalman-Filter

Die Annahme eines linearen Systemverhaltens ist für praktische Anwendungen oftmals nicht gegeben, sodass sich die Zustandsübergangsfunktion f_k nach Gleichung (2.47) sowie die Messfunktion g_k nach Gleichung (2.48) nicht als lineare Prozesse (vgl. Gleichung (2.49), (2.50)) abbilden lassen. Zwar lässt sich der Zustand \mathbf{x}_k durch f_k präzisieren, aber dennoch kann f_k nicht als Matrix dargestellt werden, um die Prozessfehlerkovarianz nach Gleichung (2.54) zu präzisieren. Gleiches gilt für g_k .

Das Erweiterte Kalman-Filter (EKF) stellt eine Erweiterung des Kalman-Filter für nichtlineare Systeme, durch Näherungen von f_k und g_k , dar (Welch und Bishop (1995)). Demnach lassen sich beide Funktionen um den aktuellen bzw. präzisierten Schätzwert linearisieren. Das Ergebnis sind die Jacobimatrizen \mathbf{F}_k und \mathbf{G}_k gemäß:

$$\mathbf{F}_k = \left. \frac{\partial f_k(\mathbf{x})}{\partial \mathbf{x}_k} \right|_{\mathbf{x}=\mathbf{x}_k} \quad (2.62)$$

$$\mathbf{G}_k = \left. \frac{\partial g_k(\mathbf{x})}{\partial \mathbf{x}_k} \right|_{\mathbf{x}=\mathbf{x}_k^*} \quad (2.63)$$

Um eine Linearisierung zweiter Ordnung zu erzielen, kann eine Ergänzung der Hessematrizen erfolgen. Für weitere Ausführungen sei auf Bar-Shalom und Li (1993) verwiesen.

Die a-posteriori PDF kann jetzt über die linearisierte Zustandsübergangsmatrix \mathbf{F}_k und die linearisierte Messmatrix \mathbf{G}_k aus den Gleichungen (2.53) bis einschließlich (2.60) des

Standard-Kalman-Filters berechnet werden. Das Ergebnis ist jedoch nicht optimal und stellt lediglich eine Näherung des Systemzustands sowie dessen Kovarianzmatrix mit:

$$p(\mathbf{x}_k | \mathbf{y}_{1:k}) \approx \mathcal{N}(\mathbf{x}_k, \mathbf{P}_k) \quad (2.64)$$

dar. Die Ursache hierfür liegt zum einen in der Linearisierung um einen Schätzwert anstelle des wahren Zustands, zum anderen bleiben Terme höherer Ordnung für eine Linearisierung unberücksichtigt. Bei Betrachtung großer Nichtlinearitäten kann dies zum Divergieren des Filters führen.

Für die Zustandsschätzung stark nichtlinearer Systeme liefern weitere Derivate der Kalman-Filterung, wie beispielsweise das Sigma-Punkt Kalman-Filter, bessere Ergebnisse. Für eine vertiefende Ausführung sei an dieser Stelle auf Van Der Merwe (2004) verwiesen.

Partikel-Filter

Für nichtlineare Schätzprobleme bieten Kalman-Filter-Varianten aufgrund ihrer analytischen Methoden keine optimale Lösung der Zustandsbestimmung (siehe Gleichung (2.64)) an. Alternativ dazu stellen numerische Verfahren, wie beispielsweise das *Partikel-Filter* eine bessere Approximation derartigen Systemverhaltens dar.

Das Partikel-Filter beruht auf der *Monte-Carlo-Integration* zur Bestimmung einer nichtlinearen a-posteriori Wahrscheinlichkeitsdichtefunktion (PDF) und ist auch als *Monte-Carlo-Methode* bekannt. Hierbei wird die PDF durch eine geeignete Anzahl an Testvektoren angenähert und ermöglicht dadurch die Schätzung einer beliebigen Verteilungsfunktion. Doucet und Johansen (2009)

Monte-Carlo-Integration Die numerische Integration nimmt sich der Erhebung beliebiger Integrale:

$$I = \int_{\mathbb{R}^n} g(x) dx \quad (2.65)$$

an. Für die Monte-Carlo-Verfahren lässt sich Gleichung (2.65) als Produkt in die Form:

$$I = \int_{\mathbb{R}^n} f(x) \pi(x) dx \quad (2.66)$$

überführen, wobei $\pi(x)$ eine positive Funktion darstellt, die sich gemäß:

$$\pi(x) \geq 0, \quad \int_{\mathbb{R}^n} \pi(x) dx = 1 \quad (2.67)$$

zu Eins summiert. Anhand dieser Eigenschaften kann $\pi(x)$ als Wahrscheinlichkeitsdichtefunktion aufgefasst werden und stellt in Bezug zur Bayes-Filterung die a-posteriori PDF mit:

$$\pi(x) = p(\mathbf{x} | \mathbf{y}) \quad (2.68)$$

dar. Für den Partikel-Filter gilt weiterhin die Annahme, dass die Verteilung der Wahrscheinlichkeitsdichte von $\pi(x)$ durch eine Menge an Stichproben $\chi^{(m)}$, $m \in [1, M^x]$, von $f(x)$ mit $M^x \gg 1$ repräsentierbar ist. Eine einzelne Stichprobe entspricht in diesem Zusammenhang einem möglichen Systemzustand und wird im Folgenden als Partikel bezeichnet. Die Monte-Carlo-Schätzung des Integrals nach Gleichung (2.65) wird als Mittelwert aller Partikel berechnet zu:

$$f_{M^x} = \frac{1}{M^x} \sum_{m=1}^{M^x} f(\chi^{(m)}). \quad (2.69)$$

Die Anzahl der Partikel M^x bestimmt die Genauigkeit der Schätzung, sodass der Approximierungsfehler der zu schätzenden PDF mit $\epsilon = f_{M^x} - I$ für $M^x \rightarrow \infty$ gegen Null strebt. Bergman (1999)

Ebenso, wie alle in diesem Kapitel vorgestellten Verfahren der Zustandsschätzung, arbeitet der Algorithmus des Partikel-Filters rekursiv, sodass die a-posteriori Wahrscheinlichkeitsdichte $p(\mathbf{x}_k | \mathbf{y}_k)$ zum Zeitpunkt k rekursiv aus $p(\mathbf{x}_{k-1} | \mathbf{y}_{k-1})$ hervorgeht. Konkret bedeutet dies, dass die Menge an Partikeln $\mathcal{X}_k := (\chi_k^{(1)}, \dots, \chi_k^{(M^x)})$ der Menge \mathcal{X}_{k-1} entstammt. Das Partikel-Filter wird aus diesem Grund auch als *sequentielle Monte-Carlo-Methode* bezeichnet. Es existiert eine Vielzahl an Ausprägungen der Monte-Carlo-Methode. Im Folgenden wird das Verfahren des Sequential Importance Resampling (SIR) näher vorgestellt.

Sequential Importance Resampling SIR beschreibt die Näherung einer Dichteverteilungsfunktion $p(\mathbf{x}_k | \mathbf{y}_k)$ durch eine Menge an gewichteten Partikeln mit:

$$\left\{ (w_k^{(m)}, \chi_k^{(m)}) : m \in [1, M^x] \right\}, \quad (2.70)$$

wobei $w_k^{(m)}$ das Gewicht des Partikels mit:

$$\sum_m w_k^{(m)} = 1 \quad (2.71)$$

darstellt.

Der SIR-Algorithmus besteht aus folgenden Verarbeitungsschritten:

1. Prädiziere alle Partikel des letzten Zeitschritts $\chi_{k-1}^{(m)}$ auf den aktuellen Zeitschritt k gemäß der Zustandsübergangsverteilung zu:

$$\chi_k^{(m)} \sim p(\mathbf{x}_k | \mathbf{u}_k, \chi_{k-1}^{(m)}) \quad (2.72)$$

2. Bestimme das Gewicht aller $m \in M^x$ Partikel anhand der neuen Messung zu:

$$w_k^{*(m)} = p(\mathbf{y}_k | \chi_k^{(m)}) \quad (2.73)$$

3. Normalisiere $w_k^{*(m)}$ gemäß:

$$w_k^{(m)} = \frac{w_k^{*(m)}}{\sum_j w_k^{*(j)}}, \quad (2.74)$$

sodass (2.71) erfüllt ist.

4. Resampling: Ziehe für alle $m \in M^\chi$ einen Index i entsprechend des Gewichts $w_k^{(m)}$ aus $m \in [1, M^\chi]$ und ersetze anschließend $\chi_k^{(m)}$ mit $\chi_k^{(i)}$. Die normalisierten Gewichte lassen sich als Wahrscheinlichkeiten interpretieren. Demnach werden Partikel mit einem hohen Gewicht häufiger gezogen.

Ohne die Ausführung des Verarbeitungsschritts 4 entspricht der Algorithmus dem Sequential Importance Sampling (SIS)-Partikel-Filter. SIS hat den Nachteil, dass die gewichtete Partikelmenge nach mehreren Iterationen degeneriert Doucet u. a. (2000), sodass gilt:

$$w_k^{(d)} \rightarrow 1, \text{ mit } d \in [1, M] \quad \wedge \quad w_k^{(m)} \rightarrow 0, \forall m \in [1, M] \setminus \{d\}. \quad (2.75)$$

Der Resampling Schritt verhindert ein Degenerieren der Partikelmenge und ermöglicht somit eine geeignete Schätzung der PDF über mehrere Zeitschritte.

Kapitel 3

Stand der Technik

Kapitel 3 fasst den Stand der Technik durch das Vorstellen aktueller Forschungsprojekte (Kapitel 3.1) und gegenwärtiger Methoden der Umfeldmodellierung (Kapitel 3.2) zusammen. Kapitel 3.3 zeigt den weiterführenden Forschungsbedarf auf.

3.1 Aktuelle Forschungsprojekte

Die Vision des unfallfreien Verkehrs setzt Schwerpunkte für die Fahrerassistenzforschung. Gefördert durch öffentliche Einrichtungen werden diese in gemeinsamen Projekten verschiedener Forschungseinrichtungen und der Automobilindustrie adressiert. Es folgt eine Vorstellung aktueller Forschungsprojekte.

3.1.1 sim^{TD}

sim^{TD} ist ein gemeinschaftliches Projekt verschiedener Automobilhersteller, Automobilzulieferer, Kommunikationsunternehmen sowie nationalen Forschungseinrichtungen zur Vernetzung von Verkehrsteilnehmern und der Verkehrsinfrastruktur. Die Förderung erfolgt über die Bundesministerien für Wirtschaft und Technologie, für Bildung und Forschung sowie für Verkehr, Bau und Stadtentwicklung.

Durch den Einsatz von Fahrzeug-zu-Infrastruktur-Kommunikation soll die Verkehrssicherheit erhöht und die Leistungsfähigkeit des vorhandenen Verkehrsnetzes gesteigert werden. Im Speziellen beinhaltet dies das Erfassen der Verkehrslage und ergänzender Informationen für die Verkehrsflussinformation, Navigation und Verkehrsflusssteuerung. Weitere Ziele umfassen die lokale Gefahrenwarnung sowie die Fahrerassistenz für Verkehrszeichen, Lichtsignalanlagen und Kreuzungsbereiche.

Die eingesetzte Sensorik konzentriert sich auf die Funkverbindung zwischen den Verkehrsteilnehmern und der Infrastruktur. Hierfür kommt eine für die Automobilindustrie entwickelte Funktechnik, der IEEE 802.11p WLAN-Standard, zum Einsatz. VDA (2012); simTD (2013)

3.1.2 Ko-FAS

Die von dem Bundesministerium für Wirtschaft und Technologie geförderte Forschungsinitiative Ko-FAS verfolgt das Ziel einer Steigerung der Verkehrssicherheit durch die Reduktion von Verkehrsunfällen sowie einer Minderung der Unfallschwere. Die Projektpartner umfassen Vertreter der Automobilindustrie/-zulieferer sowie zahlreiche Forschungseinrichtungen.

Im Rahmen von Ko-FAS werden innovative Technologien, Komponenten und Systeme zur Erstellung eines umfassenden Abbilds der Verkehrsumgebung entwickelt. Dieses Abbild basiert auf dem Austausch fahrzeuglokaler Sensorinformationen zwischen verschiedenen Verkehrsteilnehmern und wird als kooperative Sensorik und Perzeption bezeichnet. Die eingesetzte Sensorik ist vielfältig und stützt sich auf die in Kapitel 2.1 angeführten Umfeldsensoren. Weiterhin findet die Transponder-Technologie sowie die in sim^{TD} entwickelte Kommunikationstechnik Anwendung.

Ko-FAS besteht aus drei Verbundprojekten, dem Ko-Tag, Ko-PER und Ko-KOMP. Ko-Tag untersucht kooperative Sensortechnologien basierend auf einer Transponderlösung. Der Fokus liegt dabei auf dem Schutz von besonders verletztlichen Verkehrsteilnehmern, wie beispielsweise Fussgängern. Die von Fussgängern mitgeführte Sendeeinheit kann mit der Ortungseinheit in Fahrzeugen spezifische Informationen austauschen, um mögliche Kollisionsrisiken der Verkehrsteilnehmer zu berechnen.

Ko-PER beschäftigt sich mit der vollständigen Erfassung der lokalen Verkehrsumgebung. Hierfür erfolgt der Austausch von lokalen Sensordaten über eine drahtlose Kommunikationseinheit. Die kooperative Perzeption resultiert aus dem Zusammenführen interner¹ sowie externer² Sensorinformationen.

Ko-KOMP ergänzt die bereits angeführten Verbundprojekte mittels einer Wirksamkeitsanalyse unterschiedlicher, kooperativer Sensortechnologien. Ko-FAS (2013)

3.1.3 interactIVe

interactIVe ist ein von der Europäischen Kommission gefördertes Projekt mit 29 Partnern aus 10 verschiedenen Ländern. Darunter befinden sich führende Automobilhersteller/-zulieferer, zahlreiche Forschungseinrichtungen sowie hochspezialisierte Kleinunternehmen. Es handelt sich hierbei um das Nachfolgeprojekt von PReVENT Forwiss (2013), mit dem Ziel des unfallfreien Verkehrs durch einen aktiven Eingriff in die Fahrzeugführung. In diesem Kontext erfolgt u. a. die Entwicklung und Evaluierung der Wirksamkeit von kombinierten Lenk- und Bremseingriffen sowie die Verbesserung der Manöverentscheidung für aktive Sicherheitseingriffe. Diese Systeme bedienen sich einer innovativen Umfeldwahrnehmung, die auf der Kombination und der Fusion verschiedener Sensordaten beruht. Neben den in Kapitel 2.1 vorgestellten Sensoren werden Informationen aus digitalen Karten, Ultraschall sowie Fahrzeug-zu-Infrastruktur-Kommunikation in die Umfeldmodellierung integriert. Ein weiterer Projektschwerpunkt liegt auf der Entwicklung von Evaluierungsmethoden zur Bewertung von Sicherheitsfunktionen. Dies umfasst ein modulares Framework mit spezifizierten Testfällen. interactIVe (2013)

¹lokale Sensordaten

²Sensordaten anderer Verkehrsteilnehmer sowie der Infrastruktur

3.1.4 ARTRAC

ARTRAC ist ein von der Europäischen Kommission gefördertes Projekt mit sieben Partnern aus der Automobilindustrie, verschiedenen Forschungseinrichtungen sowie einem Automobilzulieferer.

Das Projektziel beinhaltet den Schutz von verletzlichen Verkehrsteilnehmern, wie beispielsweise Fussgänger und Radfahrer. Die verwendete Sensorik zum Erfassen und Verfolgen von Verkehrsteilnehmern basiert hierbei auf einem 24 GHz Radar, welches als zentrale Datenquelle für die Umfelderkennung fungiert. Auf Basis der Radardaten soll die Detektion und Verfolgung bis hin zur Klassifizierung von Verkehrsteilnehmern erfolgen. Durch den aktiven Brems- und Lenkeingriff assistiert das System bei der Kollisionsvermeidung bzw. Minderung von Unfallfolgen. Ein weiteres Ziel ist die Analyse der Fahrbahnbeschaffenheit hinsichtlich ihrer Reibungseigenschaften, um vor reibungsarmen Fahrbelägen, bedingt durch beispielsweise Glätte oder Schnee, zu warnen.

Basierend auf nur einem Sensor ermöglichen diese Fahrerassistenzfunktionen einen kostengünstigen Einsatz im Volumensegment. ARTRAC (2013)

3.1.5 V-Charge

Das Forschungsprojekt umfasst insgesamt sechs europäische Partner mit Vertretern aus der Automobilindustrie sowie verschiedenen Hochschulen. Die Förderung erfolgt über die Europäische Kommission. Der Projektschwerpunkt liegt auf der autonomen Fahrzeugführung im Kontext des Parkens und Ladens von Elektrofahrzeugen. Hierfür sind stadttähnliche Szenarien mit seriennaher Umfeldsensorik zu bewältigen. Die daraus resultierenden Forschungsfelder lassen sich in die Fahrzeugfunktionalität, das logische Konzept und die Funktionalität der Infrastruktur unterteilen.

Die Fahrzeugfunktionalität umfasst die Datenfusion verschiedener Sensoren, wie beispielsweise einer Stereokamera, eines Radars und Ultraschallsensoren, für das Erfassen des statischen und dynamischen Umfelds. Basierend auf diesem Umfeldmodell erfolgt eine Situationsanalyse unter Berücksichtigung digitaler Karteninformationen sowie der Kommunikation mit der Infrastruktur. Die Fahrzeuglokalisierung beruht auf der Kombination von Standard GPS-Daten und der visuellen Lokalisierung aus Kameradaten. Die logistische Herausforderung besteht in der Entwicklung und Umsetzung eines Konzepts für effizientes Laden und Zuweisen von Parkmöglichkeiten. V-Charge (2013)

3.1.6 UR:BAN

Das Verbundprojekt UR:BAN wird durch das Bundesministerium für Wirtschaft und Technologie gefördert und vereint 30 Projektpartner aus der Automobil- und Zuliefererindustrie, Elektronik-, Kommunikations- und Softwareunternehmen sowie Universitäten und Forschungsinstitute. Ebenso wie in den Vorgängerprojekten Prometheus, MoTiV und invent werden in UR:BAN die Themenfelder Fahrerassistenz- und Verkehrsmanagementsysteme adressiert. Der Fokus liegt hierbei auf dem städtischen Anwendungsgebiet mit den Schwerpunkten kognitive Assistenz, vernetzte Verkehrssysteme und der Mensch im Verkehr.

Die kognitive Assistenz bezieht Informationen aus einer modellbehafteten Umfeldrepräsentation und widmet sich dem Schutz von schwächeren Verkehrsteilnehmern, der Kollisionsvermeidung durch Ausweichen oder Bremsen sowie der sicheren Quer- und Längsführung. Die für das Umfeldmodell eingesetzte Sensorik ist vielfältig und stützt sich vor allem auf die in Kapitel 2.1 vorgestellten Technologien. Für die Anwendung der vernetzten Verkehrssysteme steht das energie- und verkehrsoptimierte Fahren, durch das Berücksichtigen von Informationen kooperativer Infrastruktur, im Vordergrund. Der dritte Schwerpunkt, der Mensch im Verkehr, beschäftigt sich u. a. mit einer stadtgerechten Mensch-Maschine-Interaktion sowie der Verhaltensprädiktion und der Intentionserkennung von Verkehrsteilnehmern. Hipp (2012); UR:BAN (2013)

Die in dieser Arbeit vorgestellten Algorithmen entstanden im Rahmen der kognitiven Assistenz des Verbundprojekts UR:BAN.

3.2 Kartierung und Verfolgung von Umfeldobjekten

Kapitel 3.1 zeigt, dass die Beobachtung der Umfeldobjekte von beachtlicher Bedeutung für die Realisierung diverser Fahrerassistenz- und Sicherheitsfunktionen ist. Viele Objekte stellen dabei für das eigene Verkehrsmittel ein Hindernis dar und sind möglichst genau bezüglich ihrer Form- und Dynamikeigenschaften zu beschreiben. Prinzipiell lassen sich Objekte nach ihrer Dynamikeigenschaft in zwei Kategorien, *statisch* und *dynamisch*, unterteilen.

Die Beobachtung statischer Objekte geht auf die Anfänge der mobilen Robotik zurück und ist ein Teilgebiet der Simultaneous Localization and Mapping (SLAM) - Problematik Thrun u. a. (2005). Unter SLAM ist die Lokalisierung eines mit Sensorik ausgestatteten mobilen Geräts, wie beispielsweise ein Roboter oder ein Fahrzeug, und die gleichzeitige Kartierung dessen Umfelds zu verstehen. Die Lokalisierung stützt sich dabei auf die aus Hindernismessungen aufgebaute Belegungskarte Elfes (1989). Belegungskarten erlauben eine Datenfusion unterschiedlicher Sensorquellen über die Zeit. Neben der anfänglichen Anwendung mit 2-D Laserscannerdaten lassen sich ebenso 3-D Laserscanner- Kammel u. a. (2008) bzw. Stereokameradaten Lategahn u. a. (2010) integrieren.

Für Belegungskarten mit einem festen Bezugspunkt gilt die Annahme, dass lediglich Messungen statischer Objekte zu integrieren sind. Wird diese verletzt, ruft dies Artefakte in der Belegungskarte hervor. Die Konsequenz ist ein realitätsfremdes Abbild der Umgebung aufgrund von dynamischen Objekten. Für den automobilen Anwendungsbereich ist die Annahme einer statischen Fahrzeugumgebung jedoch nur selten erfüllt. Die Detektion und Verfolgung bewegter Objekte (DATMO) ist daher für ADAS notwendig, um das statische Abbild der Umgebung mittels artefaktfreier Belegungskarten zu gewährleisten.

Prinzipiell folgen DATMO-Verfahren einem einheitlichen Schema. Sowohl für Radar-, Kamera- als auch Laserscannerdaten erfolgt zunächst eine Detektion von möglichen Objekten in der aktuellen Messung. Diese werden mit Detektionen vergangener Messungen assoziiert und anschließend aktualisiert Bar-Shalom und Li (1987). Das beschriebene Vorgehen zum Verfolgen von Fußgängern und Fahrzeugen wurde beispielsweise in Montemerlo u. a. (2008); Urmson u. a. (2008); Ess u. a. (2010) umgesetzt.

Wang (2004) stellt ein Konzept zur Kombination von SLAM und DATMO vor. Der Ansatz basiert auf der Verwendung von Laserscannerdaten, die bezüglich ihrer Konsistenz für auf-

einanderfolgende Messungen ausgewertet werden. Um einen Vergleich der Messdaten vorzunehmen erfolgt die Transformation der aktuellen Hinderniskarte aus dem kartesischen Koordinatensystem in das Polarkoordinatensystem des Laserscanners. Abstandsänderungen in den einzelnen Winkelsegmenten der Hinderniskarte in Polarkoordinaten lassen auf dynamische Messungen schließen. Zusätzlich erfolgt die Segmentierung der aktuellen Laserscannermessungen. Übersteigt das Verhältnis von dynamisch klassifizierten Messungen zu der Gesamtanzahl an Messungen pro Segment den Schwellwert 0.5, wird das gesamte Segment als dynamisch klassifiziert. Diese Methode der Dynamikklassifikation arbeitet schwellwertbasiert und eignet sich lediglich für hinreichend schnell bewegte Objekte.

Um dennoch sich langsam bewegende Objekte zu detektieren, stellt Wang eine ergänzende Methode vor. Diese beruht auf einer Belegungskarte, die lediglich Informationen³ dynamischer Objekte enthält. Befindet sich ein Segment auf einem belegten Bereich dieser Karte, wird dies als dynamisch klassifiziert. Für die Verfolgung beweglicher Objekte nutzen Wang u. a. (2003) die Methoden des EKF in Kombination mit einem Bewegungsmodell für konstante Geschwindigkeit (CV). Weiterführende Arbeiten in Wang u. a. (2007) setzen ein Interacting Multiple Model (IMM)-Filter Zhao und Thorpe (1998) mit den Dynamikmodellen für CV und konstante Beschleunigung (CA) ein.

Vu u. a. (2008) gehen gleichermaßen vor, um dynamische Objekte zu identifizieren. Nach der Segmentierung von einzelnen Messpunkten erfolgt ein Positionsabgleich der Segmente mit den dynamischen Bereichen in einer Belegungskarte. Diese enthält Informationen aus der Beobachtung beweglicher Objekte. In Vu u. a. (2011) erfolgt eine Erweiterung der Dynamikklassifikation durch die Fusion mit Radardaten. Auf Basis von Laserscannerdaten werden als beweglich detektierte Objekte mit dynamischen Objekten der Radarmessungen assoziiert. Bei erfolgreicher Zuordnung erhält das bewegliche Objekt die Dopplergeschwindigkeit der entsprechenden Radarmessung. Die anschließende Objektverfolgung basiert in Vu und Aycard (2009) auf dem Metropolis-Hastings-Algorithmus Hastings (1970), einem Partikel-Filter-Verfahren in Kombination mit einem IMM-Verfahren. Dabei lassen sich Objekte nach folgenden vier Kategorien unterteilen: Bus, Personenkraftwagen, Zweiräder und Fußgänger. Die Modellierung der ersten drei Kategorien erfolgt anhand des Boxmodells mit festen Abmaßen⁴, den Dynamikmodellen CV, CA, konstante Gierrate (CT) sowie stationär. Fußgänger hingegen werden als Punktmodell aufgefasst und anhand des CV-Modell prädiiziert.

Petrovskaya und Thrun (2009) detektieren bewegte Objekte mit Hilfe einer Belegungskarte in Polarkoordinaten, ähnlich dem Ansatz von Wang (2004). Dabei wird das gesamte Fahrzeugumfeld in gleichgroße Kreissegmente, einen sogenannten virtuellen Scan, unterteilt. Jeder Sektor eines virtuellen Scans lässt sich entsprechend der Messungen in die Bereiche *frei*, *belegt* und *verdeckt* unterteilen. Für die Detektion von bewegten Objekten sind drei Messungen notwendig. Bei der Betrachtung eines Kreissegments modelliert die erste Messung einen belegten Bereich. Anhand der zweiten Messung kann auf die Positionsänderung des belegten Bereichs geschlossen werden. Die dritte Messung dient der Plausibilisierung des modellierten Objekts.

Die anschließende Objektbeschreibung und -verfolgung basiert auf der Darstellung als Rechteck. Das Modell verfügt über folgende Parameter: Länge, Breite sowie Schwer- und

³Trajektorien dynamischer Objekte

⁴Vorwissen für jede Kategorie

Ankerpunkt. Der Ankerpunkt dient der Bestimmung der Objektdynamik und beschreibt die Verschiebung des aktuellen Schwerpunkts gegenüber dem initialen Schwerpunkt. Demnach sind bei der Objektinitialisierung der Schwer- und Ankerpunkt identisch. Die Verschiebung des Schwerpunkts durch die Änderung der Länge oder Breite hat somit keinen Einfluss auf die Schätzung der Objektdynamik. Diese erfolgt über die Positionsänderung des Ankerpunkts unter Verwendung eines Rao-Blackwellized Partikel-Filters.

Moras u. a. (2011) verwenden ebenfalls eine Belegungskarte in Polarkoordinaten, um bewegte Objekte zu identifizieren. Dabei wird die aktuelle Messung eines Laserscanners in eine Belegungskarte überführt. Anschließend erfolgt die Fusion der Belegungskarte der aktuellen Messung mit der fusionierten Belegungskarte der vorangegangenen Messungen. Die Zellaktualisierung basiert dabei auf der Dempster-Shafer-Theorie Shafer (1976), die es erlaubt, widersprüchliche Informationen in der Zellbelegung zu erfassen. Bewegt sich ein Objekt in eine Zelle mit hoher Evidenz für den Zustand *frei*, so erhält diese Zelle die Evidenz für *belegt*.

Effertz (2008) stellt ein Verfahren für die Fusion verschiedener Sensordaten vor. Die zeitliche Verfolgung von Objekten basiert auf dem EKF. Entgegen den bereits vorgestellten Ansätzen beschreibt Effertz die Klassifikation von Messungen anhand einer Gridkarte, die Oberflächeninformationen enthält. Diese wird beispielsweise mit Stereokameradaten aktualisiert. Um die Fehlziele bei der Objektverfolgung zu minimieren, erfolgt ein Abgleich aller eingehenden Sensorrohdaten mit den Höheninformationen in der Gridkarte. Dadurch lassen sich beispielsweise Bodenmessungen eines Laserscanners, hervorgerufen durch hohe Roll- und Wankbewegungen, aus der Objektverfolgung ausschließen.

Effertz (2009) beschreibt einen weiteren Ansatz der Kombination von Belegungskarten und der Zustandsschätzung beweglicher Objekte. Neben der Schätzung der Objektdynamik mittels EKF wird die Objektkontur in einer zweidimensionalen separaten Belegungskarte, aus beispielsweise Laserscannerdaten, erfasst. Aus Gründen der Rechenkomplexität erfolgt jedoch keine vollständige Umsetzung anhand von lokal mitbewegten Belegungskarten. Anstelle dessen wird die Objektkontur durch die Akkumulation von Polygonkonturen angenähert.

Gegenläufig zu den angeführten Arbeiten modellieren Moosmann und Fraichard (2010) statische und dynamische Objekte gleichermaßen, sodass die Notwendigkeit von DATMO nicht gegeben ist. Die Objektverfolgung arbeitet modellfrei und beruht auf der Akkumulation von 3-D Punktwolken in einem objektlokalen Raum. Dieser Raum ist durch objektlokale Koordinatensysteme beschrieben. Als Datenquelle dient ein mehr-ebenen Laserscanner, der das Umfeld in Distanzbildern Hoover u. a. (1996) erfasst.

Die zeitliche Filterung der Objekte, repräsentiert durch dreidimensionale, objektlokale Koordinatensysteme⁵, erfolgt anhand eines EKF und dem CV-Modell. Für bereits detektierte Objekte findet ein Abgleich der lokalen 3-D Punktwolke mit der aktuellen Messung statt. Dabei wird jedem 3-D Punkt des Objekts der nächste räumliche 3-D Punkt der aktuellen Messung zugeordnet. Anschließend folgt die Registrierung der beiden 3-D Punktwolken⁶ mit Hilfe des Iterative Closest Point (ICP)-Verfahrens Chen und Medioni (1991). Das

⁵der Zustandsvektor umfasst die Objektposition, -orientierung, -geschwindigkeit und Winkelgeschwindigkeit

⁶Punktwolke des Objekts und zugeordnete Punktwolke der Messung

Ergebnis der Registrierung, die Positions- und Orientierungsabweichung, wird zur Aktualisierung des Systemzustands im EKF genutzt.

Es folgt die Segmentierung der aktuellen Messung mit anschließender Assoziation der Segmente mit den bereits detektierten Objekten. Bei erfolgreicher Zuordnung werden die 3-D Punkte des Segments⁷ und die 3-D Punkte des Objekts zusammengeführt. Andernfalls initialisiert das Segment ein neues Objekt. Um die Anzahl der einzelnen 3-D Punkte pro Objekt zu limitieren, erfolgt die Erweiterung der bestehenden Punktwolke lediglich, wenn die Distanz nach Gleichung (2.9) zu den benachbarten 3-D Punkten den Schwellwert 1 übersteigt.

Nguyen (2012) stellt einen Ansatz zur Kopplung der modellbasierten Objektverfolgung und einer Belegungskarte vor. Hierbei erfolgt die Trennung von statischen und bewegten Objekten. Basierend auf Stereokameradaten ist die Detektion und Verfolgung dynamischer Objekte mit Hilfe des erweiterten Kalman-Filters realisiert. Dementgegen sind alle statischen Hindernisse in einer Belegungskarte erfasst.

Die Zuordnung von Sensorrohdaten zu bereits detektierten dynamischen Objekten ermöglicht eine Klassifizierung der Stereokameradaten in statisch und bewegt. Dadurch lassen sich einzelne Messungen dynamischer Objekte aus der Belegungskarte ausschließen, sobald diese mit dem modellbasierten Ansatz detektiert und verfolgt werden.

Bouzouraa und Hofmann (2010, 2011) detektieren bewegte Objekte mit Hilfe der Differenzbildung zweier Belegungskarten. Laserscannerdaten einer Messung werden in eine Belegungskarte überführt und mit der über die Zeit akkumulierten Belegungskarte verglichen. Widersprüche in den Zellen bezüglich des Status *frei* und *belegt* lassen auf Messpunkte bewegter Objekte schließen.

Anschließend folgt eine distanzbasierte Gruppierung der als dynamisch klassifizierten Messpunkte. Die Objektbildung⁸ der Segmente beruht auf der Erkennung von Kantenzügen und Eckpunkten nach Mendes u. a. (2004). Der resultierende Quader liefert eine Beschreibung des Objekts bezüglich seiner Position, Dimension und Orientierung.

Bouzouraa (2012) verwendet den Kalman-basierten Schätzalgorithmus für das zeitliche Filtern der Position, Geschwindigkeit und Beschleunigung. Die Modellierung der Objektdynamik erfolgt anhand des CA-Modells. Die geometrischen Abmaße der Objekte werden über eine gleitende Mittelwertbildung bestimmt. Neben der modellbasierten Objektbeschreibung verfügt jedes bewegte Objekt über eine Liste zugehöriger Zellen, in Form von Zellposition und Belegungsinformation, aus einer dreidimensionalen Belegungskarte. Das Mitführen der Zellen arbeitet schwellwertbasiert, sodass Zellen anhand ihrer Belegungswahrscheinlichkeit in die Liste aufgenommen bzw. aus dieser entfernt werden. Der Alterungsmechanismus der Belegungskarte bedingt ein kontinuierliches Bestätigen der Zellen durch neue Messungen, um eine zeitlich konsistente Konturinformation zu gewährleisten.

Steinemann u. a. (2012) stellen einen modellfreien Ansatz der Objektverfolgung aus 3-D Laserscannerdaten vor. Dieser basiert auf der Akkumulation von, dem Objekt zugehörigen, Lidarmessungen in separaten, dreidimensionalen Belegungskarten. Das Verfahren beruht auf dem Partikel-Filter, welcher ähnlich zu Moosmann und Fraichard (2010) die Position und Bewegung der lokalen Belegungskarte schätzt. Ein Set an Partikeln repräsentiert da-

⁷3-D Punkte aus der aktuellen Messung

⁸Quadermodell

bei mögliche Systemzustände⁹. Die Modellierung der Objektdynamik erfolgt anhand des Einspurmodells (Schindler (2007)).

Der Fokus dieser Arbeit liegt auf der Registrierung von aktuellen Messungen in der bestehenden Belegungskarte. Steinemann erläutert verschiedene Kostenfunktionen, um die Übereinstimmung der Registrierung zu bewerten. Der Ansatz beschreibt die Verfolgung eines einzelnen Objekts, welches in seiner Rechenkomplexität bereits die Echtzeitanforderung übersteigt.

Eine Alternative zu den bereits vorgestellten Verfahren der Objektdetektion und -verfolgung bietet die Methodik *track-before-detect* Davey u. a. (2007). Gegenläufig zu der Beobachtung detektierter Objekte¹⁰ basiert dieser Ansatz auf der zeitlichen Filterung abstrahierter Sensordaten. Die Detektion bewegter Objekte lässt sich anschließend aus der Dynamik der zeitlich verfolgten Sensordaten ableiten.

Eine bekannte Arbeit auf diesem Gebiet stammt von Pfeiffer und Franke (2010), die eine Stereokamera als Sensorquelle verwenden und eine Quantisierung im Bildbereich entlang der Bildspalten vornehmen. Die Gruppierung mehrerer Pixel wird als *Stixel* bezeichnet. Mit Hilfe des EKF erfolgt die Dynamikschätzung der einzelnen Stixel in kartesischen Koordinaten. Anschließend ermöglichen die dynamischen Stixel eine Formulierung der in dem Sensorsichtfeld erfassten Objekte Erbs u. a. (2011).

Brechtel u. a. (2010) verfolgen einen ähnlichen Ansatz, basierend auf 3-D Lidardaten. Eine zweidimensionale Belegungskarte diskretisiert die Fahrbahnebene in gleichgroße Zellen. Neben der Belegungswahrscheinlichkeit besitzt jede Zelle einen Geschwindigkeitsvektor. Durch die Verwendung des Partikel-Filters erfolgt die Dynamikschätzung der einzelnen Zellen über die Zeit.

3.3 Weiterführender Forschungsbedarf

Der aufgezeigte Stand der Technik verdeutlicht die Notwendigkeit der präzisen Beschreibung von Umfeldobjekten bezüglich ihrer Form und Bewegung. Dabei ermöglicht die Kombination der modellfreien¹¹ und modellbehafteten¹² Objekterfassung ein konsistentes Abbild der Umgebung für statische sowie dynamische Hindernisse.

Die Arbeiten von Wang (2004); Vu u. a. (2008); Petrovskaya und Thrun (2009); Moras u. a. (2011); Effertz (2008) realisieren eine Dynamikklassifikation für Laserscannerdaten, um eine separate Verarbeitung von stationären und bewegten Objekten vorzunehmen. Einerseits erfolgt das Abbild statischer Objekte ohne jegliche Formmodelle in diskreten Zellen einer Belegungskarte. Andererseits sind dynamische Objekte als Rechteck bzw. Quader für die zeitliche Verfolgung mittels Kalman-Filter-Algorithmen modelliert und stellen oftmals keine optimale Näherung der Objektkontur dar.

Weitere Ansätze eines hybriden Umfeldmodells beinhalten die Arbeiten von Effertz (2009); Bouzouraa (2012); Steinemann u. a. (2012). Bouzouraa schätzt die Dynamikinformation von bewegten Objekten mittels EKF. Anhand der Objektposition und -geschwindigkeit

⁹Pose der Belegungskarte

¹⁰modelliert aus Sensordaten

¹¹in Form einer Belegungskarte

¹²beispielsweise mittels EKF

erfolgt eine Verschiebung der dem Objekt zugeordneten Zellen in einer Belegungskarte. Dadurch lässt sich jedes Objekt anhand von diskreten Zellen in seiner Form beschreiben. Eine Schwierigkeit dieses Ansatzes besteht in der Entscheidung, welche Zellen dem jeweiligen Objekt zugehörig sind. Die schwellwertbasierte Auswahl geht mit einer zusätzlichen Diskretisierung¹³ der Daten für die Objektbeschreibung einher.

Effertz hingegen beschreibt die Idee einer objektlokalen Belegungskarte, die mit dem Objekt mitgeführt wird. Der Ansatz bietet ebenfalls die Möglichkeit einer modellfreien Repräsentation der Objektkontur, basierend auf Laserscannerdaten. Aus Gründen der Echtzeitanforderung erfolgte keine experimentelle Umsetzung des Ansatzes. Alternativ nutzt Effertz Polygonzüge, um eine flexible Formbeschreibung bewegter Objekte zu realisieren. Steinemanns Arbeit stellt eine erste Implementierung der objektlokalen Belegungskarte, basierend auf dreidimensionalen Laserscannerdaten, für Fahrzeuge dar. Die Objektdynamik wird unter Verwendung des Einspurmodells durch einen Partikel-Filter geschätzt. Die Herausforderung besteht dabei in der Registrierung einzelner Messungen in einer separaten Belegungskarte. Die Umsetzung des Verfahrens zur Modellierung und Verfolgung eines einzelnen Objekts übersteigt bereits die Echtzeitanforderung.

Gegenwärtige Forschungsaktivitäten zeigen Bestrebungen, die Verfahren der modellfreien sowie modellbasierten Umfelderkennung zu kombinieren, um ein gesamtheitliches und konsistentes Abbild der Fahrzeugumgebung zu liefern. Alle angeführten Arbeiten beziehen sich dabei auf die Verarbeitung von Laserscannerdaten. Die Schätzung der Form und Bewegung von Objekten erfolgt weitestgehend modellbasiert und stellt oftmals keine optimale Lösung dar. Die Bereitstellung von einzelnen, dem Objekt zugehörigen, Belegungskarten ist eine vielversprechende Methode für eine modellfreie Formrepräsentation bewegter Objekte. Der damit einhergehende Rechenaufwand ist eine große Herausforderung für die Echtzeitfähigkeit derartiger Systeme.

Diese Arbeit betrachtet eine echtzeitfähige Umsetzung der Form- und Bewegungsschätzung bewegter Objekte mittels objektlokaler Belegungskarten. Der Fokus dieser Arbeit liegt dabei auf der Verwendung von Stereokameradaten, einer modellfreien Repräsentation bewegter Objekte sowie einer verbesserten Bewegungsschätzung anhand der Konturschätzung, basierend auf individuellen Belegungskarten.

¹³erste Diskretisierung erfolgt durch Projektion von Rohdaten auf Belegungsgitter

Kapitel 4

Modellbasierte Objektbeschreibung und -verfolgung

Die modellbasierte Objektbeschreibung und -verfolgung befasst sich mit der Objektrepräsentation in Form von Zuständen (siehe Kapitel 4.2) sowie deren zeitliche Filterung. Dabei dienen die dem Objekt zugewiesenen Eigenschaften beispielsweise der Beschreibung der Form (siehe Kapitel 4.5) oder der Bewegung (siehe Kapitel 4.3). Die Schätzung der Zustände erfolgt mittels DBN (vgl. Abbildung 2.9) (siehe Kapitel 2.5.2) und lässt sich aufgrund der für die Umfeldsensorik nicht messbaren Steuerungsgrößen \mathbf{u} anhand der Abbildung 4.1 vereinfachen. Diese Steuerungsgrößen sind beispielsweise der aktuelle Lenkwinkel oder die Gaspedalstellung anderer Fahrzeuge.

Aus der Abbildung geht hervor, dass sich die Zustände \mathbf{x}_k der Objekte anhand von Messungen \mathbf{y}_k zu diskreten Zeitpunkten beobachten lassen.

Im Verlauf dieses Kapitels wird die modellbasierte Objektbeschreibung anhand der Kalman-Filterung näher beschrieben und stützt sich dabei auf die in Kapitel 2.5.3 vorgestellten Grundlagen. Das Kalman-Filter beruht auf drei elementaren Schritten Skutec (2006):

1. **Prädiktion:** Der erste Schritt prädiziert die aktuelle Schätzung, den Systemzustand \mathbf{x}_k sowie die Kovarianzmatrix \mathbf{P}_k auf den nächsten Messzeitpunkt $k + 1$, unter der Annahme bestimmter Bewegungsmodelle.
2. **Assoziation:** Der zweite Schritt ordnet der prädizierten Schätzung \mathbf{x}_{k+1}^* eine Messung \mathbf{y}_{k+1} zu.
3. **Innovation:** Der dritte Schritt aktualisiert die Schätzung durch die Integration der zugeordneten Messung. Dabei nehmen die Prädiktion und die Messung anhand ihrer Unsicherheiten einen gewichteten Einfluss auf die Zustandsaktualisierung.




Abbildung 4.1: Objektverfolgung als graphische Darstellung des Bayes-Netzwerks




Abbildung 4.2: Kalman-Filter-Darstellung eines Iterationszyklus am Beispiel einer eindimensionalen Wahrscheinlichkeitsverteilung: (1) Ausgehend von der aktuellen Zustandsschätzung erfolgt die Vorhersage für den nächsten Messzeitpunkt unter Berücksichtigung physikalischer Gesetzmäßigkeiten in Form von Bewegungsmodellen. (2) Diese Modelle stellen eine Näherung gegenüber der tatsächlichen Bewegung dar. Der entstehende Fehler kann durch das Prozessrauschen modelliert und in der Prädiktion berücksichtigt werden. (3) Anschließend erfolgt die Aktualisierung der Zustandsschätzung, basierend auf der Differenz zwischen Prädiktion und Messung. In Anlehnung an Lindl (2009)

Abbildung 4.2 stellt die iterative Funktionsweise des Kalman-Filters beispielhaft anhand eines Zyklus dar. In diesem Beispiel gilt die Assoziation als gegeben. Für eine nähere Betrachtung der Zuordnungsproblematik wird an dieser Stelle auf Kapitel 4.8 verwiesen.

4.1 Motivation

Eine adäquate Schätzung der Objekteigenschaften von, aus dem Fahrzeugumfeld stammenden Verkehrsteilnehmern ist für ADAS essentiell. Sowohl Sicherheits- als auch Komfortfunktionen regeln das Fahrverhalten des eigenen Fahrzeugs anhand der Form und Dynamik anderer Verkehrsteilnehmer. Als Beispiele sind PreCrash-Funktionen oder der Spurwechselassistent zu nennen. Hierbei entscheidet die Qualität der geschätzten Objekteigenschaften über eine angemessene Ausprägung der Fahr- bzw. Sicherheitsfunktion. Daraus ergibt sich eine Vielzahl an Herausforderungen für die Umfelderkennung. Zum einen existieren im Fahrzeugumfeld zahlreiche Objekte, die sich hinsichtlich ihrer Form und Art

der Bewegung voneinander unterscheiden. Zum anderen ist eine gesamtheitliche Beobachtung dieser Objekte nicht zu jedem Zeitpunkt gewährleistet. Eine teilweise bzw. vollständige Verdeckung, hervorgerufen durch die Grenzen des Sensorsichtfelds oder andere Objekte, erschweren die Objektverfolgung und -repräsentation. Zusätzlich ist jede Messung mit einer sensorspezifischen Ungenauigkeit behaftet und liefert somit lediglich einen Schätzwert. Diese Ungenauigkeit sowie die Variationen der Objekterscheinung gilt es mit entsprechenden Algorithmen für die Form- und Bewegungsschätzung zu behandeln. Ziel ist es, alle für ADAS relevanten Objekte zu jedem Zeitpunkt adäquat zu beschreiben.

4.2 Systemzustand

Die Umfeldwahrnehmung für ADAS modelliert verschiedene Objekte aus dem Straßenverkehr. Dazu zählen neben motorisierten Verkehrsteilnehmern, wie dem Personenkraftwagen, dem Lastkraftwagen und dem Kraftomnibus, im Besonderen verletzbare Verkehrsteilnehmer, beispielsweise Motorradfahrer, Fahrradfahrer sowie Fußgänger. Wie bereits angeführt, lassen sich Objekte des Fahrzeugumfelds über verschiedene Zustände beschreiben. Der Systemzustand \mathbf{x} stellt eine Vereinfachung der realen Objekterscheinung in abstrakter und kompakter Weise dar und beinhaltet alle zu schätzenden Eigenschaften der Objekte. In diesem Zusammenhang ist eine minimale Beschreibung \mathbf{x}_p eines Objekts gemäß einer zweidimensionalen Position:

$$\mathbf{x}_p = (x, y)^T \quad (4.1)$$

gegeben. Durch die Modellierung der Form \mathbf{x}_f (siehe Kapitel 4.5) und Bewegung \mathbf{x}_m (siehe Kapitel 4.3) von Objekten erweitert sich der Systemzustand zu:

$$\mathbf{x} = \left(\mathbf{x}_p^T, \mathbf{x}_m^T, \mathbf{x}_f^T \right)^T. \quad (4.2)$$

Dabei handelt es sich um Schätzgrößen, deren Unsicherheiten durch die Zustandskovarianzmatrix \mathbf{P} beschrieben sind. Die Aktualisierung von \mathbf{x} und \mathbf{P} erfolgt über die Integration von Sensormessungen \mathbf{y} anhand der in Kapitel 2.5.3 eingeführten Kalman-Filterung. Es folgt eine Vorstellung ausgewählter Form- und Bewegungsmodelle.

4.3 Bewegungsmodelle

Das Bewegungsmodell dient der Prädiktion des Systemzustands \mathbf{x}_{k-1} des Zeitpunkts $k-1$ auf den Zeitpunkt k nach Gleichung (2.47). Durch die Annahme der nicht messbaren Steuerungsanteile \mathbf{u} und dem mittelwertfreien Prozessrauschen \mathbf{w}_{k-1} nach Gleichung (2.51) reduziert sich der Zustandsübergang zu:

$$\mathbf{x}_k = f_k(\mathbf{x}_{k-1}). \quad (4.3)$$

Die jeweilige Objektbewegung ist dabei stark abhängig von der Art des Objekts. Beispielsweise lässt sich ein Bewegungsmodell eines Fahrzeugs aufgrund einer höheren Trägheit

sowie einer eingeschränkten Bewegungsfreiheit deutlich einfacher aufstellen, als ein Bewegungsmodell eines Fußgängers.

Bewegungsmodelle lassen sich entsprechend ihrer Komplexität in geradlinige und kurvenförmige Modelle unterteilen. Zur Kategorie der geradlinigen Modelle gehört das konstante Geschwindigkeit (CV)- und das konstante Beschleunigung (CA)-Modell. Deren Vorteil liegt in einem linearen Übergang des Systemzustands zwischen zwei aufeinander folgenden Zeitschritten.

Demgegenüber stehen kurvenförmige Bewegungsmodelle, wie beispielsweise die Modelle für konstante Gierwinkel und Geschwindigkeit (CSAV), konstante Gierwinkel und Beschleunigung (CSAA), konstante Gierrate und Geschwindigkeit (CTRV) und konstante Gierrate und Beschleunigung (CTRA). Dabei modellieren CSAV und CSAA eine Bewegung entlang eines Kreises, CTRV und CTRA hingegen eine Bewegung entlang einer Klothoide.

4.3.1 Konstante Geschwindigkeit in kartesischen Koordinaten

Die Beschreibung der Objektdynamik als CV-Modell erfolgt über die Modellierung der Objektgeschwindigkeit v nach Gleichung (4.2) mit:

$$\mathbf{x}_m = (v_x, v_y)^T. \quad (4.4)$$

Das CV-Modell beschreibt eine gleichförmige Bewegung, deren Geschwindigkeit sich weder in Richtung noch Betrag ändert. Demnach ergibt sich folgende Gleichung für den Zustandsübergang von einem Zeitpunkt $k - 1$ zu einem Zeitpunkt k :

$$\mathbf{x}_k = \mathbf{x}_{k-1} + \begin{pmatrix} v_{x,k-1} \Delta t \\ v_{y,k-1} \Delta t \\ 0 \\ 0 \end{pmatrix}. \quad (4.5)$$

4.3.2 Konstante Beschleunigung in kartesischen Koordinaten

Das Modell der CA bildet eine Objektbewegung unter der Annahme einer gleichbleibenden Objektbeschleunigung a mit:

$$\mathbf{x}_m = (v_x, v_y, a_x, a_y)^T, \quad (4.6)$$

ab. Die entsprechende Gleichung für den Zustandsübergang von einem Zeitpunkt $k - 1$ auf den Zeitpunkt k ist definiert zu:

$$\mathbf{x}_k = \mathbf{x}_{k-1} + \Delta t \begin{pmatrix} v_{x,k-1} + \frac{1}{2} a_{x,k-1} \Delta t \\ v_{y,k-1} + \frac{1}{2} a_{y,k-1} \Delta t \\ a_{x,k-1} \\ a_{y,k-1} \\ 0 \\ 0 \end{pmatrix}. \quad (4.7)$$

4.3.3 Konstante Gierrate und Geschwindigkeit in Polarkoordinaten

Die Geschwindigkeit der Gleichung (4.4) lässt sich in Polarkoordinaten anhand von $(v, \psi)^T$ darstellen. Der Betrag der Geschwindigkeit sowie die Orientierung ergeben sich zu:

$$v = \sqrt{v_x^2 + v_y^2} \quad , \quad \psi = \arctan\left(\frac{v_y}{v_x}\right). \quad (4.8)$$

Weiterhin ist die Schätzung der Gierrate $\dot{\psi}$ erforderlich, sodass der Systemzustand für das CTRV-Modell definiert ist zu:

$$\mathbf{x} = (x, y, \psi, v, \dot{\psi})^T. \quad (4.9)$$

Dessen Zustandsübergangsfunktion des Zeitpunkts $t - 1$ auf den Zeitpunkt t lautet:

$$\mathbf{x}_k = \mathbf{x}_{k-1} + \begin{pmatrix} v_{k-1}(\dot{\psi}_{k-1})^{-1} \left[\sin(\psi_{k-1} + \dot{\psi}_{k-1}\Delta t) - \sin(\psi_{k-1}) \right] \\ v_{k-1}(\dot{\psi}_{k-1})^{-1} \left[\cos(\psi_{k-1}) - \cos(\psi_{k-1} + \dot{\psi}_{k-1}\Delta t) \right] \\ \dot{\psi}_{k-1}\Delta t \\ 0 \\ 0 \end{pmatrix}. \quad (4.10)$$

4.3.4 Konstante Gierrate und Beschleunigung in Polarkoordinaten

Im Vergleich zu Gleichung (4.9) ist der Systemzustand für das Modell der CTRA um die Beschleunigung a erweitert:

$$\mathbf{x} = (x, y, \psi, v, a, \dot{\psi})^T. \quad (4.11)$$

Der resultierende Zustandsübergang ergibt sich zu:

$$\mathbf{x}_k = \mathbf{x}_{k-1} + \begin{pmatrix} \frac{v_{k-1} + \frac{1}{2}a_{k-1}\Delta t}{(\dot{\psi}_{k-1})} \left[\sin(\psi_{k-1} + \dot{\psi}_{k-1}\Delta t) - \sin(\psi_{k-1}) \right] \\ \frac{v_{k-1} + \frac{1}{2}a_{k-1}\Delta t}{(\dot{\psi}_{k-1})} \left[\cos(\psi_{k-1}) - \cos(\psi_{k-1} + \dot{\psi}_{k-1}\Delta t) \right] \\ \dot{\psi}_{k-1}\Delta t \\ a_{k-1}\Delta t \\ 0 \\ 0 \end{pmatrix}. \quad (4.12)$$

4.3.5 Zusammenfassung

Die vorgestellten Modelle dienen der Approximation von Bewegungen entlang geradliniger bzw. kurvenartiger Trajektorien. Prinzipiell lassen sich komplexere Bewegungsmodelle in einfachere Modelle überführen. Beispielsweise kann durch die Vernachlässigung der Beschleunigung mit $a = 0$ ein Modellwechsel von CA nach CV erfolgen. Für weiterführende

Informationen zur Bewegungsmodellierung im Kontext der Kalman-Filterung wird an dieser Stelle auf Bar-Shalom und Li (1995); Li und Jilkov (2003) verwiesen.

Aus dem empirischen Vergleich der Fahrzeugeigenbewegungsschätzung für verschiedene Bewegungsmodelle Schubert u. a. (2011) geht hervor, dass das CTRA-Modell gegenüber dem CTRV-Modell lediglich eine geringfügige Verbesserung der Bewegungsschätzung bei ausreichend häufiger Messung darstellt. Demnach ist das CTRV-Modell dem CTRA-Modell aufgrund des geringeren Berechnungsaufwands bei vergleichbaren Ergebnissen vorzuziehen und wird in dieser Arbeit angewendet.

4.4 Kompensation der Eigenbewegung

Durch die Bewegung des Sensorfahrzeugs und der Bewegung der Umfeldobjekte liegen Sensormessungen einer überlagerten Bewegung zugrunde. Diese Überlagerung ist für eine sinnvolle Interpretation der Messungen in der Objektmodellierung zu berücksichtigen.

Die Fahrzeugeigenbewegung umfasst in der vorliegenden Arbeit die absolute Geschwindigkeit v_{ego} sowie die Gierrate $\dot{\psi}_{ego}$. Diese werden mit Hilfe der in Kapitel 2.2 vorgestellten fahrzeugeigenen Sensorik erfasst. Zur Schätzung der Fahrzeugeigenbewegung $\mathbf{x}_{ego} = (v_{ego}, \dot{\psi}_{ego})^T$, der Messunsicherheiten in Form der zugehörigen Kovarianzmatrix \mathbf{P}_{ego} sowie der Kompensation dieser Bewegung findet das Verfahren aus Stüker (2004) Anwendung. Es stützt sich auf die in Kapitel 2.5.3 vorgestellte Kalman-Filterung der angeführten Messgrößen.

4.5 Formmodelle

Die Beschreibung der Objektgestalt ist neben der Schätzung der Objektbewegung für ADAS von großem Interesse. Dabei orientiert sich die Auswahl des Formmodells zum einen an den Anforderungen der Anwendung, zum anderen an den durch die Sensorik messbaren Größen. Aus der Literatur geht eine Vielzahl an Formmodellen zur Beschreibung mehrdimensionaler Festkörper hervor. Abbildung 4.3 bietet eine grafische Übersicht möglicher Konturmodelle am Beispiel eines Fahrzeugs.

Für die einfachste Beschreibung der Objektform, dem Punktmodell (Abbildung 4.3a), ist der Systemzustand mit:

$$\mathbf{x} = (\mathbf{x}_p^T, \mathbf{x}_m^T)^T \quad (4.13)$$

bereits vollständig beschrieben. Für die Modelle 4.3b bis 4.3e hingegen ist der Systemzustand nach Gleichung (4.2) mit:

$$\mathbf{x}_f = (l, b, h)^T \quad (4.14)$$

zu erweitern.

Dyckmanns u. a. (2011) realisieren die Verfolgung von Objekten, basierend auf der dem Sensor sichtbaren Objektkonturlinie (4.3b). Demnach bezieht sich l auf die Länge der sichtbaren Objektseite und kann somit die Objektlänge bzw. die Objektbreite annehmen. Die Objektbreite sowie die Objekthöhe sind jedoch in diesem Modell nicht berücksichtigt und ergeben sich somit zu $b = 0$ und $h = 0$.




Abbildung 4.3: Übersicht geometrischer Grundkörper als Konturmodelle am Beispielobjekt Fahrzeug: (a)-Schwerpunkt, (b)-Linie, (c)-Rechteck, (d)-Quader, (e)-Ellipse

Das Rechteckmodell (Abbildung 4.3c) findet beispielsweise Anwendung in der Arbeit von Streller und Dietmayer (2004). Hierfür werden vordefinierte Breiten und Längen für verschiedene Objektklassen modelliert. Die Objekthöhe ist kein Bestandteil des Modells ($h = 0$). Ein weiterer Anwendungsbereich des Modells bezieht sich auf die Objektverfolgung in zweidimensionalen Bilddaten. Hierfür werden beispielsweise Fahrzeuge oder Fußgänger als Rechteck modelliert und über die Zeit verfolgt (Cielniak u. a. (2010)). Aufbauend auf dem Rechteckmodell lassen sich Objekte durch das Schätzen der Höheninformation nach Abbildung 4.3d als Quader darstellen. Diese Form der Objektrepräsentation findet vorrangig Einsatz in der Objektverfolgung auf Basis von 3-D Punktwolken¹, wie beispielsweise in Himmelsbach u. a. (2008); Erbs u. a. (2011).

Die Verwendung von Ellipsen zur Beschreibung der Objektform (Abbildung 4.3e) erfolgt vorwiegend für Objekte, deren Gestalt sich über die Zeit ändert. Dazu zählen beispielsweise Fußgänger, deren Gliedmaßen eine Bewegung unabhängig von dem Oberkörper erlauben

¹3-D Sensorik: Stereokamera, Mehrebenen-Laserscanner

und sich mit jeweils einer Ellipse modellieren lassen (Lee u. a. (2003)).

4.6 Messmodelle

Das Messmodell stellt nach Gleichung (2.50) den Zusammenhang zwischen dem Messraum und dem Zustandsraum her. Dabei überführt die Messmatrix \mathbf{G} den Systemzustand \mathbf{x} in eine äquivalente Messung \mathbf{y} und ist somit abhängig von den entsprechenden Messgrößen des Sensors. Demnach ist das Messmodell sensorspezifisch und nicht verallgemeinerbar. Anhand eines einfachen Beispiels wird dieser Sachverhalt näher erläutert.

Ist der Systemzustand mit $\mathbf{x} = (x, y, v_x, v_y)^T$ und eine 2-D Positionsmessung (beispielsweise von einem ein-ebenen Laserscanner) mit:

$$\mathbf{y} = (x, y)^T \quad (4.15)$$

gegeben, so ergibt sich die Messmatrix zu:

$$\mathbf{G} = \begin{pmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \end{pmatrix}. \quad (4.16)$$

Die Unsicherheit der Messung lässt sich als Kovarianzmatrix \mathbf{R} (2.52) mit:

$$\mathbf{R} = \begin{pmatrix} \sigma_x^2 & 0 \\ 0 & \sigma_y^2 \end{pmatrix} \quad (4.17)$$

abbilden. Dabei stellt (σ_x, σ_y) die Standardabweichungen entlang der x - bzw. y -Koordinate dar. Diese beiden Größen sind abhängig von dem Rauschverhalten der eingesetzten Sensorik und werden meist empirisch bestimmt.

4.7 Referenzpunktumschaltung

Die Referenzpunktumschaltung hat die Aufgabe, die Schätzung der Objektbewegung von der Objektform zu entkoppeln. Die Bewegung von Objekten leitet sich oftmals von der Objektposition ab, da nur wenige Sensoren in der Lage sind, die Objektdynamik direkt zu messen.

Abbildung 4.3 zeigt verschiedene Formmodelle, bei denen sich die Objektposition \mathbf{x}_p auf den Schwerpunkt des jeweiligen geometrischen Körpers bezieht. Dementsprechend setzt die korrekte Modellierung der Objektposition eine genaue Bestimmung der Formgrößen voraus. Eine fehlerhafte Schätzung der Objektform wirkt sich somit direkt auf die Schätzung des Schwerpunkts und der Objektdynamik aus.

Ausgehend von dem physikalischen Messprinzip der Sensoren ist die Bestimmung der korrekten Objektgröße nicht jederzeit gewährleistet, da beispielsweise Teilverdeckungen oder fehlerhafte Messgrößen die Messungen des Objekts verfälschen. Die Referenzpunktumschaltung adressiert dieses Problem und bietet nach Abbildung 4.4 zehn verschiedene




Abbildung 4.4: Übersicht möglicher Referenzpunkte an einem Objekt: Die Position des lokalen Objektkoordinatensystems (rot) ist hierbei mit dem RP₅ angegeben. Bezogen auf das Objekt erfolgt die Zuordnung der Referenzpunkte mit: 1 - links vorn, 2 - vorn mittig, 3 - rechts vorn, 4 - rechts mittig, 5 - rechts hinten, 6 - hinten mittig, 7 - links hinten, 8 - links mittig, 9 - Objektzentrum, 0 - unbekannt.

RP an, um zu jeder Zeit eine durch die Sensorik am besten messbare Objektposition zu bestimmen.

Hat der Sensor eine uneingeschränkte Sicht auf das Objekt, ist meist der dem Sensor räumlich am nächsten zugeordnete RP ebenfalls der am besten messbare. Wechselt dieser Punkt mit der Zeit, kann mit Hilfe der Objektdimensionen eine Umrechnung der Referenzpunkte erfolgen. Für ausführliche Informationen zur Umrechnung der Referenzpunkte wird auf Schueler u. a. (2012) verwiesen.

Abbildung 4.5 zeigt zwei Objekte, deren Positionen, gekennzeichnet durch den jeweiligen RP, zu den Zeitpunkten t_0 und t_1 geschätzt werden. Dabei befindet sich das Objekt 1 vollständig im Sensorsichtfeld. Dessen Bewegung lässt sich mit Hilfe der Positionsmessung am RP₇ ermitteln. Das Objekt 2 hingegen stellt ein in den Sensorsichtbereich einfahrendes Objekt dar. Erfolgt hierbei die Wahl des RP₅, so weist das Objekt zwischen beiden Zeitpunkten keinerlei Bewegung auf. Um auf die korrekte Objektdynamik zu schließen, ist in diesem Fall die Wahl des RP₃ besser geeignet, da dieser die Positionsänderung des Objekts vollständig abbildet.

Das angeführte Beispiel macht die Problematik der Referenzpunktvergabe deutlich. Abhängig von der eingesetzten Sensorik sowie der jeweiligen Situation ist die Wahl des RP entscheidend, um eine realitätsnahe Schätzung der Objektbewegung zu gewährleisten. Kapitel 6.3.2 befasst sich näher mit der Formulierung geeigneter Objekthypothesen und Po-

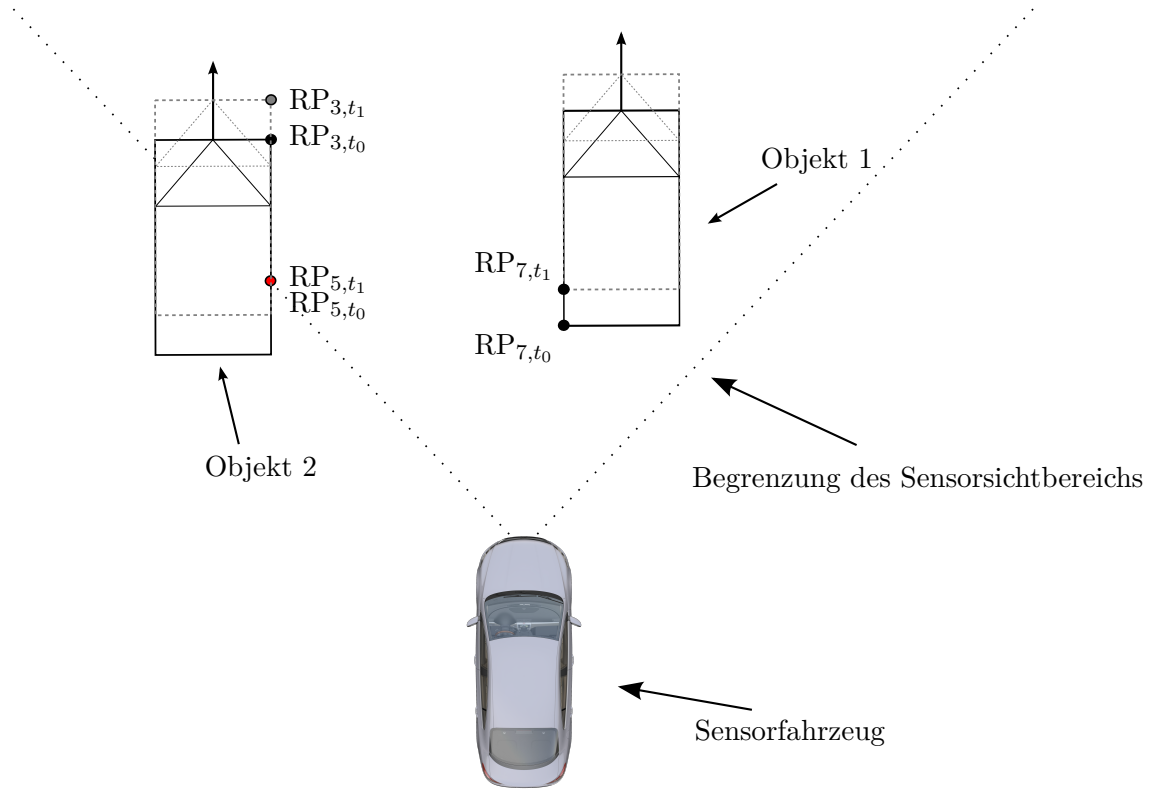


Abbildung 4.5: Beispielhafte Darstellung der Referenzpunktvergabe zweier Objekte zu den Zeitpunkten t_0 und t_1 : Das Objekt 1 ist uneingeschränkt im Sensorerfassungsbereich sichtbar. Der resultierende RP befindet sich auf der hinteren linken Ecke (RP_7). Das Objekt 2 stellt ein, in den Sensorsichtbereich ein-fahrendes, Fahrzeug dar. Der Für die Beobachtung der Objektdynamik ist RP_3 dem RP_5 (rot) vorzuziehen, da in diesem Punkt die Bewegung sichtbar ist.

sitionsangaben aus Sensormessungen.

4.8 Multiobjektverfolgung

Die Berücksichtigung verschiedener Verkehrsteilnehmer ist in besonderem Maße für das Beherrschen komplexer Fahrsituationen² mit Hilfe von ADAS notwendig. Dementsprechend ist das gleichzeitige Verfolgen mehrerer Objekte \mathbf{x}_i mit $\{i \in \mathbb{N}, 1 \leq i \leq N\}$ erforderlich und wird in dieser Arbeit mit einem Multiinstanz-Objektfilter umgesetzt. N bezeichnet dabei die aktuelle Anzahl der verfolgten Objekte. Die Aufgaben der Multiobjektverfolgung beinhalten das Initialisieren und Verwalten separater Zustandsfilter für jedes zu beobachtende Objekt. Dadurch ergeben sich verschiedene Problemstellungen:

- Die tatsächliche Anzahl der zu verfolgenden Objekte \tilde{N} ist zeitvariant und unbekannt.
- Die Anzahl der Sensormessungen ist ebenfalls zeitvariant und unterliegt zusätzlichen Einflussfaktoren, beispielsweise sensorspezifischen Fehldetektionen.
- Die Zuordnung zwischen Messungen und Objekten³ ist nicht bekannt und gilt für die Zustandsschätzung mittels Bayes als Voraussetzung.
- Die Beobachtbarkeit einzelner Objekte kann durch andere Objekte beeinflusst werden, beispielsweise im Fall der Teil- oder Vollverdeckung.

Die tatsächliche Anzahl an Objekten \tilde{N} einer Verkehrsszene wird als Objekt-Kardinalität bezeichnet. Um das zeitvariante \tilde{N} bestmöglich schätzen zu können, ist hinsichtlich der Objektverwaltung das Hinzufügen und das Entfernen einzelner Objekte zu gewährleisten. Weiterhin sind sensorspezifische Problemstellungen, wie beispielsweise das Ausfallen von Messungen (Fehldetektionen) oder das Auftreten von Falschalarmen zu berücksichtigen, da sich diese unmittelbar auf die Schätzung von \tilde{N} auswirken.

4.8.1 Datenassoziation

Ausgehend von \tilde{M} Sensormessungen mit unbekannter Zuordnung zu den N aktuell beobachteten Objekten ergibt sich das nicht triviale Problem der Datenassoziation. Diese Zuordnung lässt sich in zwei Teilschritte gliedern:

- Ausschluss von möglichen Zuordnungen über vorgegebene Suchbereiche
- Auswahl jener Zuordnungen, die das gewählte Kriterium optimal erfüllen

Das Resultat stellt die Assoziationsmatrix $\mathbf{A} \in \{0, 1\}^{N \times \tilde{M}}$ dar, die mit:

$$\mathbf{A}_{ij} = 1 \Leftrightarrow \mathbf{x}_i \leftrightarrow \mathbf{y}_j \quad (4.18)$$

²beispielsweise urbanes Kreuzungsszenario

³auch als Datenassoziation bezeichnet




Abbildung 4.6: Beispielhafte Darstellung von Prädiktion, Messung und Suchbereichen zur Datenassoziation

eine Zuordnung des Objektzustands x_i und der Messung y_j vornimmt. Als Maß für die Zuordnung dient häufig die Mahalanobis-Distanz, welche sich im Fall der Kalman-Filterung nach Gleichung (2.9) mit $M = S_{ij}^{-1}$ berechnen lässt.

Für die Datenassoziation sind prinzipiell zwei Fehler zu vermeiden Stüker (2004):

- Verfehlte Assoziation: Eine Messung wird dem zugehörigen Objekt nicht zugeordnet.
- Falsche Assoziation: Eine Messung wird einem anderen Objekt zugeordnet.

Durch die verfehlte Assoziation wird der Zustand des entsprechenden Objekts in diesem Zeitschritt nicht aktualisiert. Dies kann zur Initialisierung eines neuen Objekts führen. Eine falsche Assoziation nimmt eine fehlerhafte Aktualisierung des Objektzustands vor und verschlechtert somit dessen Schätzung.

4.8.2 Suchbereiche

Für praktische Anwendungen stellt das Berechnen der Assoziationsmatrix unter Verwendung des Mahalanobis-Abstands einen rechenintensiven Verarbeitungsschritt dar. Um diesen möglichst effizient zu gestalten, sind ungeeignete Paare von der Berechnung auszuschließen. Deren Eintrag in die Assoziationsmatrix resultiert dabei zu $A_{ij} = 0$. Eine wirksame Methode für den Ausschluss unwahrscheinlicher Zuordnungen stellt die Einführung von Suchbereichen dar. Deren Form kann beispielsweise eine kreisförmige, rechteckige oder elliptische Gestalt annehmen BLACKMAN und POPOLI (1999). In dieser Arbeit erfolgt die Reduzierung notwendiger Assoziationsberechnungen durch kreisförmige Suchbereiche.

Abbildung 4.6 zeigt eine Anordnung möglicher Prädiktionen x_i^* mit zugehörigem Suchbereich sowie mehrerer Messungen y_j . Die Messungen 1 bis 3 lassen sich direkt den Prädiktionen 1 bis 3 zuordnen, da diese jeweils nur in einen Suchbereich fallen. Messung 4 kann

zu keiner Prädiktion assoziiert werden, da sie sich ausserhalb aller möglichen Suchbereiche befindet. Das Resultat ist die Initialisierung eines neuen Objekts. Messung 5 befindet sich sowohl in Suchbereich 2 als auch in Suchbereich 3 und ist dadurch nicht konfliktfrei assoziierbar. Dieser Konflikt muss mit Hilfe eines Zuordnungsverfahrens gelöst werden.

4.8.3 Zuordnungsverfahren

Mit Hilfe der Suchbereiche findet eine Selektion der zu assoziierenden Messungen statt. Aufgabe der Zuordnungsverfahren ist eine optimale Zuweisung der Messungen zu den prädizierten Objekten. Es existiert eine Vielzahl an Verfahren, um dieses Optimierungsproblem zu lösen. Diese lassen sich in *Alle-Nachbar-Verfahren* und *Ein-Nachbar-Verfahren* unterteilen.

Für erstere erfolgt eine gewichtete Zuweisung aller Messungen zu jedem Objekt. Demnach nehmen zu jedem Messzeitpunkt alle Messungen Einfluss auf die Schätzung des jeweiligen Objekts. Ein in der Literatur bekannter Vertreter dieses Verfahrens ist das Probabilistic Data Association Filter (PDAF). In Bezug auf die zeitliche Filterung von Objekten erfolgte die Ableitung mehrerer Derivate, wie beispielsweise dem Joint Probabilistic Data Association Filter (JPDAF) (Schulz u. a. (2003)) oder dem Generalized Probabilistic Data Association Filter (GPDAF) nach Schubert u. a. (2012), um das Assoziationsproblem für stark verrauschte Sensordaten optimal zu lösen.

Ein-Nachbar-Verfahren sind durch die optimale Zuordnung einer Messung \mathbf{y}_j zu genau einem prädizierten Objekt \mathbf{x}_i^* charakterisiert. Dadurch findet eine eindeutige Zuweisung von \mathbf{y}_j zu \mathbf{x}_i^* statt, bei der die nicht assoziierten Messungen keinen Einfluss auf die Zustandsschätzung des Objekts ausüben. Die einfachste Methode stellt das *iterative* Nearest-Neighbour-Verfahren dar. Dabei wird genau die Messung dem prädizierten Objekt zugeordnet, die innerhalb des jeweiligen Suchbereichs den geringsten euklidischen Abstand aufweist. Der Rechenaufwand ist aufgrund der einfachen Algorithmik gering. Eine Erweiterung des iterativen Vorgehens stellt das *globale* Nearest-Neighbour-Verfahren dar. Im Gegensatz zur lokalen Optimierung wird hierbei ein globales Optimum der Assoziation aller Messungen und der prädizierten Objekte gesucht Konstantinova u. a. (2003), woraus eine deutlich höhere Rechenzeit resultiert.

Abbildung 4.7 veranschaulicht den Unterschied beider Algorithmen. Die iterative Funktionsweise bietet in diesem Fall lediglich eine Näherungslösung, wogegen der globale Algorithmus die optimale Lösung erzielt. Der Einsatz des globalen Nearest-Neighbour-Verfahrens ist dem des iterativen Verfahrens in stark belebten Szenen, gekennzeichnet durch eine hohe Anzahl an Objekten und Messungen, vorzuziehen. Sind jedoch die Abstände zwischen den Objekten ausreichend groß, so liefert der iterative Ansatz ähnliche Ergebnisse bei verhältnismäßig stark reduziertem Rechenaufwand.

Die Objektverfolgung in dieser Arbeit beruht auf der Assoziation des iterativen Nearest-Neighbour-Verfahrens.




Abbildung 4.7: Vergleichendes Resultat zweier Zuordnungsverfahren anhand der gleichen Ausgangslage: Der iterative Nearest-Neighbour-Algorithmus ermittelt keine optimale Lösung ($\mathbf{x}_1^* \leftrightarrow \mathbf{y}_1, \mathbf{x}_2^* \leftrightarrow \mathbf{y}_2$) des Assoziationsproblems. In Anlehnung an Stüker (2004)

4.9 Zusammenfassung und Diskussion


Die vorgestellten Methoden zur Objektverfolgung basieren auf der Formulierung von Modellen. Diese beschreiben die Bewegung sowie die Form der zu beobachtenden Objekte. Der Zustandsvektor \mathbf{x} fasst die aktuellen Modelleigenschaften der Objekte zusammen. Deren Unsicherheiten werden in Form der Kovarianzmatrix \mathbf{P} geschätzt. Mit Hilfe von Messmodellen erfolgt die Integration von Sensormessungen, um die Zustände der jeweiligen Objekte zu aktualisieren. Dem vorausgesetzt ist ein Assoziationsschritt, der eine Zuordnung der aktuellen Messungen zu den prädizierten Objekten vornimmt. Das Ergebnis der modellbasierten Objektbeschreibung ist beispielhaft in Abbildung 4.8 dargestellt. Abbildung 4.8a zeigt das Referenzbild der aktuellen Szene sowie die detektierten Objekte (gelb). Abbildung 4.8b hingegen visualisiert die aktuell im Fahrzeugumfeld befindlichen Objekte in Quaderform (gelb) (4.14) aus der Vogelperspektive.

Die modellbasierte Umfelderkennung zeichnet sich u. a. durch die Trennfähigkeit der beobachteten Objekte aus. Zu jedem Zeitpunkt ist demnach die Betrachtung der Eigenschaften einzelner Objekte anhand der jeweiligen Zustandsvektoren \mathbf{x}_i gewährleistet. Basierend auf dem Objektzustand lässt sich zusätzlich eine Klassifikation bezüglich der Dynamik oder der Art des Objekts vornehmen. Weiterhin unterliegt der zu überwachende Bereich keiner Diskretisierung und ist in seiner räumlichen Ausdehnung nicht limitiert. Das heißt, der Umfelderkennungsbereich deckt sich direkt mit dem Sichtfeld der eingesetzten Sensorik und kann somit von wenigen bis mehreren hundert Metern variieren.

Aufgrund des Abbilds der Realität durch die Bewegungs- und Formmodelle stellt die Schätzung des Objektzustands lediglich eine Näherung des tatsächlichen Zustands dar. Dabei gilt es, einen Kompromiss zwischen einer detaillierten, aber rechenintensiven, und echtzeitfähigen Modellierung zu finden. Als besonders nachteilig wirkt sich eine fehlerhafte Assoziation von Messungen zu prädizierten Objekten aus. Diese verfälscht die Schätzung und kann durch Folgemessungen nicht korrigiert werden. Eine große Anzahl an Objekten auf einem örtlich begrenzten Raum bzw. Geisterziele, hervorgerufen durch die Sensorik, erhöhen das Risiko einer Fehllassoziation. Weiterhin bietet die modellbasierte Objektverfolgung keinerlei Informationen über den Erfassungsbereich zwischen den detektierten Objekten.



(a)



(b)

Abbildung 4.8: Ergebnis der modellbasierten Objekterfassung (gelb): (a) - Referenzbild mit Visualisierung der detektierten Objekte, (b) - quaderbasierte Objektdarstellung aus der Vogelperspektive

Kapitel 5

Kartenbasierte Umfeldwahrnehmung

Dieses Kapitel beschreibt Methoden der kartenbasierten Umfeldwahrnehmung. Hierbei liegt der Fokus auf dem Einsatz einer Karte zum Abbilden von Belegungswahrscheinlichkeiten¹. Die Belegungskarte wird bezüglich ihrer Datenstrukturen sowie den Mechanismen zur Aktualisierung durch Sensormessungen diskutiert. In der Literatur erfolgt deren Anwendung vorrangig für das Kartieren des statischen Fahrzeugumfelds.

5.1 Motivation

Das Fahrzeugumfeld umgibt eine Vielzahl an Hindernissen, die in Bezug auf ADAS zu Detektieren sind. Diese lassen sich anhand ihrer Dynamikeigenschaften prinzipiell in *bewegte* und *stationäre* Objekte unterteilen. Die modellbasierte Objektverfolgung (siehe Kapitel 4) eignet sich in besonderem Maße für die Beobachtung bewegter Objekte, da die Art der Bewegung sowie die Form der Objekte durch einfache geometrische Grundkörper meist hinreichend genau angenähert werden kann. Für stationäre Objekte ist die Schätzung der Dynamikeigenschaften trivial, da sie während ihrer Beobachtung keinerlei Bewegung ausführen. Die Schätzung ihrer Form hingegen gilt als anspruchsvoll, da sich die Erscheinung der Objekte oftmals nicht ausreichend genau durch geometrische Grundkörper annähern lässt und somit komplexere bzw. rechenintensive Modellierungen erfordert.

Die Umfelderkennung in Form einer Belegungskarte bietet die Möglichkeit, Objekte unabhängig von Modellen abzubilden und stellt dadurch ein geeignetes Mittel für die Erfassung stationärer Objekte dar. Zusätzlich lassen sich Unsicherheiten der Sensormessungen (Messrauschen des Sensors) in der Modellierung der Belegungswahrscheinlichkeit berücksichtigen. Im Folgenden wird die Belegungskarte bezüglich ihrer Struktur und Anwendung näher vorgestellt.

5.2 Aufbau der Gitterstruktur

Die kartenbasierte Umfeldwahrnehmung beruht auf der Diskretisierung eines definierten Raums. Dieser Bereich wird als Karte bezeichnet und durch eine Menge von Zellen z mit:

$$\mathcal{Z}_K := \{z_1, z_2, \dots, z_n\} \quad (5.1)$$

¹im Folgenden als Belegungskarte bezeichnet

repräsentiert. n beschreibt hierbei die Anzahl der Zellen z . Jede Zelle $z_l \in \mathcal{Z}_K$ kann eine beliebige Größe annehmen sowie diverse Informationen enthalten.

Die Karte bildet den beobachteten Raum lückenlos ab, sodass die Eckpunkte der einzelnen Zellen² aneinander grenzen und eine Gitterstruktur ergeben. Entsprechend der Gestalt und Anordnung der Zellen z_l sind Karten in strukturierte und unstrukturierte Abbildungen des Erfassungsbereichs zu unterteilen.

Abbildung 5.1 stellt jeweils ein Beispiel beider Kategorien grafisch dar. Strukturierte Karten bieten den Vorteil, dass sich benachbarte Zellen aufgrund ihrer äquidistanten Anordnung einfach bestimmen lassen. Für unstrukturierte Karten muss hingegen die Nachbarschaftsbeziehung in jeder Zelle abgelegt werden, um einen Zugriff zwischen benachbarten Raumelementen zu ermöglichen. Demnach benötigt diese Art der Gitterstruktur einen erhöhten Speicherbedarf ggü. strukturierten Karten.

Der Vorteil des unstrukturierten Gitters liegt in der heterogenen Raumabtastung. Zum einen ist ein feineres Auflösen interessanter Bereiche in der Karte durch eine erhöhte Anzahl an Zellen möglich, zum anderen können großflächige Zellen zum Abtasten ereignisloser Abschnitte eingesetzt werden, um die Gesamtanzahl der Kartenelemente zu reduzieren.




Abbildung 5.1: Gitterstrukturen: (a)-regelmäßige Gitter mit konstanter Raumdichte, (b)-unstrukturiertes Gitter mit variabler Raumdichte

Bezugnehmend auf ADAS wird die Gitterstruktur vorwiegend für das Abbilden von Belegungswahrscheinlichkeiten zweidimensionaler Räume genutzt Badino u. a. (2007). Darüber hinaus existieren Arbeiten zu 3-D Belegungskarten Douillard u. a. (2009). Diese treten in der Literatur nur vereinzelt auf, da der Informationsgewinn ggü. 2-D Belegungskarten den erhöhten Rechenaufwand oftmals nicht rechtfertigt. Die 2-D Belegungskarte lässt sich wie folgt beschreiben:

Definition 5.1. Eine 2-D Belegungskarte K ist durch eine Menge von Zellen $\mathcal{Z}_K := \{z_{i,j} | (i,j) \in \mathbb{N}\}$ definiert. Die Information jeder Zelle lässt sich als Vektor $z_{i,j} = (p, \Delta x_K, \Delta y_K)^T$ mit $(p, \Delta x_K, \Delta y_K) \in \mathbb{R}$ beschreiben. p repräsentiert hierbei die Belegungswahrscheinlichkeit der Zelle³, (i,j) die diskreten Kartenkoordinaten und $(\Delta x_K, \Delta y_K)$ die Zellgröße in x - und y -Richtung.

²auch als Kartenelemente bezeichnet

³im Folgenden auch als $p(z_{i,j})$ bezeichnet

Abbildung 5.2 stellt das Konzept der 2-D Belegungskarte grafisch dar. Der Zugriff auf jede Zelle erfolgt anhand der diskreten Koordinaten (i, j) . Ausgehend von dem Ursprung des Referenzkoordinatensystems lässt sich die Position von $z_{i,j}$ in euklidischen Koordinaten (x, y) durch die Transformation $T^{RKS \rightarrow BKS}$ sowie den Zellengrößen $\Delta x_K, \Delta y_K$ berechnen. Häufig sind die Zellen $z_{i,j}$ gleichgroß und besitzen mit $\Delta x_K = \Delta y_K$ eine quadratische Ausdehnung. Dies vereinfacht die Umrechnung der Punkte zwischen den verschiedenen Koordinatensystemen.




Abbildung 5.2: Konzept der 2-D-Belegungskarte

Für zweidimensionale Belegungskarten wird oftmals ein Datenfeld⁴ als informationstechnische Datenstruktur verwendet, um den entsprechenden Speicherplatz der Belegungskarte bereitzustellen sowie einen schnellen und einfachen Zugriff auf Einzelelemente zu ermöglichen.

Nähere Angaben zur Bestimmung der Belegungswahrscheinlichkeit der Zellen $p(z_{i,j})$ folgen in Kapitel 5.3. Die Integration neuer Belegungswahrscheinlichkeiten ist in Kapitel 5.4 beschrieben.

5.3 Inverses Sensormodell

Das Sensormodell ist eine mathematische Abbildungsvorschrift, die die Abbildung der realen Welt auf die Messungen eines realen Sensors approximiert. Dementsprechend beschreibt das *inverse Sensormodell* eine mathematische Abbildungsvorschrift, die eine Nä-

⁴engl. Array

herung der realen Welt durch Messungen eines realen Sensors abbildet. Das heißt, misst beispielsweise ein Laserscanner die Entfernung zu einem Objekt, lässt sich über die Strahlengometrie und die ermittelte Entfernung auf die Position des Objekts schließen.

Im Kontext der gitterbasierten Umfeldwahrnehmung stellt das inverse Sensormodell den Zusammenhang zwischen einer Sensormessung \mathbf{y}_k zum Zeitpunkt k und der Aktualisierung der Belegungskarte K dar. Die gesuchte Wahrscheinlichkeit $p(z|\mathbf{y}_k)$ der Zellen, basierend auf der Messung \mathbf{y}_k , ist abhängig von der Modellierung des Messfehlers.

Abbildung 5.3 stellt diese Abhängigkeit qualitativ für eine zweidimensionale Sensormessung dar. Ausgehend von der Sensorposition lässt sich der Sensorstrahl bis hin zu dem gemessenen Objekt bestimmen (siehe oberer Teil der Abbildung).




Abbildung 5.3: Prinzipskizze des strahlenbasierten Sensormodells am Beispiel der 2-D Belegungskarte

Alle Zellen die sich in dem Sensorstrahl befinden sind aufgrund der Messung \mathbf{y}_k zu aktualisieren. $p(z_{i,j}|\mathbf{y}_k)$ ergibt sich dabei anhand der Wahrscheinlichkeitsverteilung, dargestellt für eine Dimension im unteren Teil der Abbildung 5.3. In diesem Fall ist die Messung durch eine Normalverteilung modelliert und entlang der Kartendimension j grafisch aufgetragen. Die Wahrscheinlichkeiten lassen sich in die Kategorien *frei*, *belegt* und *unbekannt* unterteilen. Alle Zellen, die sich zwischen dem Sensor und dem Objekt befinden, werden mit der Wahrscheinlichkeit $p(z = \text{frei})$ aktualisiert. Zellen nahe der Messung⁵ erhalten eine Belegungswahrscheinlichkeit $p(z)$ entsprechend der Messwertmodellierung. Zellen hinter der Messung werden als unbekannt mit $p(z = \text{unbekannt})$ eingestuft.

⁵im Bereich $\pm 3\sigma$

5.4 Schätzung des Belegungszustands mit binärem Bayes-Filter

Die kartenbasierte Umfeldwahrnehmung beruht auf der Aktualisierung des diskretisierten Umfelds. Hierfür sind die nach Kapitel 5.3 ermittelten Belegungswahrscheinlichkeiten mehrerer Messungen in K über die Zeit zu integrieren. Die Belegungswahrscheinlichkeit der Karte zum Zeitpunkt k ist durch:

$$p_k(K) = p(K|\mathbf{y}_{1:k}) \quad (5.2)$$

gegeben und beschränkt sich auf die Abhängigkeit aller bisherigen Messungen.

Für den zweidimensionalen Anwendungsfall bedeutet dies, dass sich die Karte K aus den Zellen $z_{i,j}$ zusammensetzt. Jede Zelle enthält einen binären Wert, der die Zelle in *belegt* oder *frei* einteilt. Der Zustand *belegt* ist mit OCC und der Zustand *frei* mit $\neg OCC$ gekennzeichnet. Die Notation $p(z_{i,j} = OCC)$ bzw. $p(z_{i,j})$ bezeichnet dabei die Wahrscheinlichkeit, dass eine Zelle belegt ist.

Zur Vereinfachung der Schätzproblematik nach Gleichung 5.2 erfolgt für einen Großteil der Anwendungen von Belegungskarten die Berechnung von $p(K)$ unter der Annahme, dass die einzelnen Zellen $z_{i,j}$ voneinander unabhängig sind. Dadurch lässt sich $p(K)$ als Produkt der Einzelwahrscheinlichkeiten jeder Zelle formulieren zu:

$$p(K|\mathbf{y}_{1:k}) = \prod_{i,j} p(z_{i,j}|\mathbf{y}_{1:k}). \quad (5.3)$$

Die Wahrscheinlichkeit jeder Zelle stellt ein binäres Schätzproblem mit statischem Zustand dar und kann mit Hilfe des in Kapitel 2.5.3 vorgestellten Bayes-Filters berechnet werden. Angewandt auf die Zustandsschätzung einer Zelle in der Belegungskarte ergibt sich das logarithmische Quotientenverhältnis nach Gleichung 2.46 zu:

$$\text{logit}_k(z_{i,j}) = \log \frac{p(z_{i,j}|\mathbf{y}_k)}{1 - p(z_{i,j}|\mathbf{y}_k)} + \text{logit}_{k-1}(z_{i,j}) - \text{logit}_0(z_{i,j}). \quad (5.4)$$

Der Vorteil dieser Darstellung liegt in der numerischen Stabilität für Wahrscheinlichkeiten nahe 0 und 1. Die Initialisierung der Zellen erfolgt mit $\text{logit}_0(z_{i,j})$ (siehe Gleichung 5.4). Hierfür sind die Zustände *belegt* und *frei* als gleich wahrscheinlich mit $p(z_{i,j} = OCC) = p(z_{i,j} = \neg OCC) = 0.5$ gewählt. Damit ergibt sich der initiale Wert zu $\text{logit}_0(z_{i,j}) = 0$, wodurch sich Gleichung 5.4 vereinfacht zu:

$$\text{logit}_k(z_{i,j}) = \log \frac{p(z_{i,j}|\mathbf{y}_k)}{1 - p(z_{i,j}|\mathbf{y}_k)} + \text{logit}_{k-1}(z_{i,j}). \quad (5.5)$$

Das Berechnen der Belegungswahrscheinlichkeit jeder Zelle aus dem logarithmischen Quotientenverhältnis (5.5) erfolgt mit:

$$p(z_{i,j}|\mathbf{y}_k) = 1 - \frac{1}{1 + \exp(\text{logit}_k(z_{i,j}))}. \quad (5.6)$$

Die rekursive Darstellung nach Gleichung 5.5 ist eine effiziente Methode zur Aktualisierung des Zellinhalts. Die in dieser Arbeit verwendeten Belegungskarten sind nach dieser Darstellung implementiert.

5.5 Kompensation der Eigenbewegung

Es existieren zahlreiche Ausprägungen der Belegungskarte. Diese lassen sich hinsichtlich des Bezugskoordinatensystems in *ortsfeste* und *fahrzeugfeste* Belegungskarten unterteilen. Der Ursprung ortsfester Belegungskarten liegt in einem bei der Initialisierung festgelegten Punkt. Dieser Punkt kann eine GPS-Koordinate oder beispielsweise die aktuelle Fahrzeugposition einnehmen. Durch die Bewegung des Sensorfahrzeugs erfolgt dessen Verschiebung in Bezug auf den gewählten Kartenursprung, sodass sich das Sensorfahrzeug auf der Belegungskarte bewegt. Dementgegen befindet sich der Ursprung der fahrzeugfesten Belegungskarte am Sensorfahrzeug. Durch die Fahrzeugbewegung muss der Inhalt der Belegungskarte vor der Integration neuer Sensormessungen angepasst werden. Beide Varianten bieten Vor- und Nachteile und werden im Folgenden näher diskutiert.

Ortsfeste Belegungskarten zeichnen sich vor allem durch einen gleichbleibenden Erfassungsbereich und einen daraus resultierenden konstanten Speicherbedarf aus. Abbildung 5.4 zeigt die Aktualisierung des Speichers aufgrund der Fahrzeugeigenbewegung. Passiert das Sensorfahrzeug ein definiertes Gebiet in der Belegungskarte (siehe brauner Kreis), erfolgt die Aktualisierung des Kartenspeichers. Anstelle des Verschiebens von Zellinhalten wird eine konstante Speichergröße durch das Verwerfen veralteter Zellen (rote Zellen) hinter dem Sensorfahrzeug erreicht. Die neu angehängten Zellen (grüne Zellen) erhalten den initialen Wert nach Kapitel 5.4. Um sicher zu stellen, dass alle Sensormessungen in der Belegungskarte erfasst werden können, ist in der Entfernung der Kartenbereich größer als der Erfassungsbereich der verwendeten Sensorik zu wählen. Dies erfordert einen hohen Speicherbedarf. Zusätzlich muss für die Integration aktueller Messungen eine Transformation um die Eigenbewegung des Sensorfahrzeugs ggü. dem vorangegangenen Messzeitpunkt erfolgen.

Der benötigte Speicherbedarf von fahrzeugfesten ggü. ortsfesten Belegungskarten ist geringer, da sich der maximale Erfassungsbereich der Belegungskarte mit dem der eingesetzten Sensorik deckt. Weiterhin ist die Integration neuer Messungen lediglich durch die konstante Transformation zwischen dem Sensor und dem fahrzeugfesten Bezugskoordinatensystem erforderlich. Die Aktualisierung der Karte, bedingt durch die Eigenbewegung des Sensorfahrzeugs, erfolgt durch das Verschieben bzw. Umkopieren der Zellinhalte. Dies geht oftmals mit zeitaufwendigen Speicheroperationen einher.

5.6 Zusammenfassung und Diskussion

Wie bereits in Kapitel 5.1 angeführt, eignet sich die Belegungskarte aufgrund ihrer modellfreien Datenakkumulation besonders für die Umfeldrepräsentation stationärer Objekte. Die von der Sensorik erfassten Messungen lassen sich ohne jegliche Vorverarbeitung direkt mit Hilfe eines inversen Sensormodells (5.3) in die Belegungskarte integrieren. Die




Abbildung 5.4: Aktualisierung des Kartenspeichers aufgrund der Fahrzeugeigenbewegung, in Anlehnung an Nguyen (2012)

nicht trivialen Vorverarbeitungsschritte, wie beispielsweise eine Segmentierung der Rohdaten oder etwa eine Assoziation mit bereits detektierten Objekten, sind für diese Art der Umfeldmodellierung nicht erforderlich. Weiterhin besteht die Möglichkeit der Sensordatenfusion durch das Anbinden mehrerer Datenquellen über sensorspezifische Modelle, die u. a. das unterschiedliche Fehlerverhalten der einzelnen Sensoren berücksichtigen.

Abbildung 5.5 zeigt eine aus Stereokameradaten erstellte Belegungskarte. Hierbei sind *belegte* Bereiche in Rot, *freie* in Grün und *unbekannte* in Blau visualisiert. Im unteren rechten Teil der Abbildung ist das Referenzbild der aktuellen Szene dargestellt. Aus der Abbildung geht hervor, dass neben den in der Szene befindlichen Objekten ebenfalls der Freiraum zwischen diesen erfasst wird. Mit Hilfe einer Freibereichsextraktion Bouzouraa (2012) lässt sich zum Beispiel der befahrbare Korridor ermitteln.

Die Dimension der Belegungskarte und somit der Bereich der Umfeldmodellierung ist stark von der Rechenzeitanforderung abhängig. Dabei wirkt eine hohe Zellauflösung der Karte dem Diskretisierungsfehler der Messdaten entgegen. Die Verfeinerung der Gitterstruktur geht jedoch direkt mit einer steigenden Berechnungsdauer des Umfeldmodells einher. Demnach ist lediglich ein begrenzter Bereich um das Sensorfahrzeug modellierbar, um eine geeignete Auflösung bei gleichzeitiger Echtzeitfähigkeit zu gewährleisten.

Weiterhin bieten konventionelle Belegungskarten keine Möglichkeit der Fokussierung, so dass alle Bereiche des überwachten Raums gleich aufgelöst sind. Dadurch verteilt sich die zur Verfügung stehende Rechenkapazität gleichmäßig auf interessante sowie uninteressante




Abbildung 5.5: Darstellung einer Belegungskarte mit Bereichen dynamischer Objekte: Belegte Zellen sind in rot, freie Zellen in grün und unbekannte Zellen in blau visualisiert. Neben dem Belegungsgitter ist ein dynamisches Objekt mit relativem Geschwindigkeitsvektor in gelb hervorgehoben. Das Referenzbild der Szene ist unten rechts dargestellt.

Bereiche des Fahrzeugumfelds. Spezielle Ausprägungen der kartenbasierten Umfelderkennung adressieren genau dieses Problem durch beispielsweise einen hierarchischen Aufbau von Belegungskarten Schmid (2012).

Abbildung 5.5 zeigt ebenfalls die Auswirkung der Erfassung dynamischer Objekte (gekennzeichnet durch gelbes Rechteck) in der Belegungskarte. Durch die Bewegung des Objekts⁶ erfolgt die Integration der dem Objekt zuzuordnenden Messungen in unterschiedlichen Zellen des Belegungsgitters. Das Resultat ist ein ausgedünnter, großflächiger Bereich belegter Zellen hinter dem Objekt. Abbildung 5.6 verdeutlicht diesen Effekt der inkonsistenten Zellbelegung. Die linke Seite der Grafik zeigt ein sich vom Sensorfahrzeug entfernendes Objekt. Dieses bewirkt einen Statusübergang der Zellen von belegt zu frei. Die rechte Seite der Abbildung stellt ein sich dem Sensorfahrzeug näherndes Objekt dar, welches Zellen mit einer hohen Belegungswahrscheinlichkeit an der Vorderseite des Objekts hervorruft.

Dieser Effekt wirkt sich negativ auf die Interpretation des kartenbasierten Umfelds aus, da es die Trennung von belegten und freien Bereichen des Fahrzeugumfelds erschwert bzw. zu Fehldetektionen führt.

Eine weitere Eigenschaft der Belegungskarte ist die Superposition von räumlich nah bei-

⁶Objekt entfernt sich vom Sensorfahrzeug

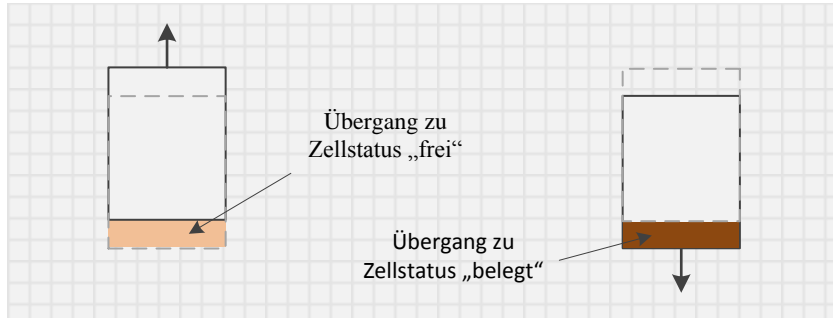


Abbildung 5.6: Effekt der Belegungsinkonsistenz aufgrund dynamischer Objekte: links - sich vom Sensorfahrzeug entfernendes Objekt, rechts - sich dem Sensorfahrzeug näherndes Objekt.

einander liegenden Messungen. Demzufolge können Messungen unterschiedlicher Objekte den Belegungszustand gleicher Gitterzellen $p(z_{i,j})$ beeinflussen. Diese Charakteristik ist in Abbildung 5.7 für den eindimensionalen Fall dargestellt. Die Abbildung zeigt zwei Messungen unterschiedlicher Objekte mit der jeweiligen Unsicherheitsverteilung (gaussähnlicher Funktionsverlauf). Unter der Abszisse ist die resultierende Belegung der Gitterzellen farblich visualisiert. Der konstante Farbverlauf der Zellen (gesättigtes Rot) zwischen den Maxima der beiden Messungen verdeutlicht die Überlagerung beider Objekte in dem Belegungsgitter.




Abbildung 5.7: Superposition der Messungen unterschiedlicher Objekte für die Aktualisierung der Belegungsinformation: Das Farbschema der Zellbelegungswahrscheinlichkeit verläuft von Grün (frei) bis hin zu gesättigtem Rot (belegt).

Dieser Effekt zeigt, dass sich die kartenbasierte Darstellung lediglich für eine Aussage bezüglich belegter, freier und unbekannter Bereiche eignet. Der Rückschluss auf die Anzahl und die Lage von Objekten aus dem Belegungsgitter ist aufgrund einer möglichen Superposition einzelner Messungen nicht fehlerfrei möglich, da die Trennfähigkeit der Objekte anhand der Belegungswahrscheinlichkeit nicht gewährleistet ist.

Kapitel 6

Objektverfolgung mittels objektlokaler Belegungskarten

6.1 Einleitung

Dieses Kapitel beschreibt den kombinierten Ansatz der modell- und kartenbasierten Umfelderkennung zur Verfolgung bewegter Objekte. Dabei stellt die Multiobjektverfolgung auf Basis von Sensorrohdaten den Ausgangspunkt für das hybride Umfeldmodell dar. Dem folgend werden die Voraussetzungen sowie die Implementierung des kombinierten Ansatzes für eine verbesserte Umfelderkennung diskutiert.

6.1.1 Motivation

Die Bestrebung zur Entwicklung eines kombinierten Verfahrens zur Verfolgung bewegter Objekte resultiert aus den Vor- und Nachteilen der angeführten Umfelderkennungsmethoden nach Kapitel 4 und Kapitel 5. Tabelle 6.1 fasst die in Kapitel 4.9 und 5.6 diskutierten Eigenschaften der jeweiligen Methoden zusammen. Die Gegenüberstellung verdeutlicht das weitestgehend komplementäre Verhalten der beiden Verfahren hinsichtlich der aufgelisteten Kriterien. Dabei zeichnet sich die modellbasierte Vorgehensweise durch eine besonders gute Trennfähigkeit der Objekte, einem variablen Erfassungsbereich sowie der guten Fokussierbarkeit auf die für die Umfelderkennung relevanten Bereiche aus. Demgegenüber bietet das kartenbasierte Verfahren die Option, Bereiche zwischen den Objekten zu interpretieren und somit Aussagen über Freiräume und unbekannte Areale zu treffen. Die Interpretation beruht dabei auf einer detaillierten Umfelderkennung mit geringer Messwertabstraktion. Die Kombination beider Ansätze zur Verfolgung von Objekten bietet die Möglichkeit, die jeweiligen Stärken beider Verfahren für eine verbesserte Schätzung der Objektbewegung und -erscheinung zu erzielen. Im Folgenden wird das Konzept der Objektverfolgung mittels OLK vorgestellt.

6.1.2 Konzept

Das Konzept der Objektverfolgung mittels OLK erweitert die modellbasierte Umfeldwahrnehmung durch die Zuordnung einzelner Belegungskitter zu jedem erfassten Objekt. Abbildung 6.1 zeigt eine Übersicht der Systemarchitektur. Prinzipiell lassen sich die einzelnen

Tabelle 6.1: Gegenüberstellung der modell- und kartenbasierten Umfelderkennung

Umfelderfassung	modellbasiert	kartenbasiert
Trennfähigkeit der Objekte	+	-
Dynamikklassifikation der Objekte	+	o
Objektklassifikation	o	-
Erfassungsbereich	+	-
Freibereichsdetektion	-	+
Fokussierbarkeit	+	-
Abstraktion der Messwerte*	-	+
Diskretisierung der Messwerte	+	-**
Sensordatenfusion	o	+

'+' gut, 'o' mittel, '-' schlecht

* eine geringe Messwertabstraktion wird in diesem Vergleich als gut befunden

** abhängig von der Diskretisierung des Erfassungsbereichs

Verarbeitungsschritte drei Modulen, der *Datenvorverarbeitung*, den *lokalen Belegungskarten* sowie der *Objektverfolgung*, zuordnen. Dabei beinhaltet die Datenvorverarbeitung die Segmentierung der Sensorrohdaten sowie die anschließende Objekthypothesenbildung. Die Objektverfolgung nutzt die erstellten Hypothesen, um neue Objekte für eine zeitliche Filterung zu initialisieren bzw. bestehende Objekte zu aktualisieren. Das Modul der OLK hat die Aufgabe, für jedes Objekt ein eigenständiges Belegungsgitter zu verwalten und alle Rohdaten, die zur Aktualisierung der Objekte in der modellbasierten Objektverfolgung führen, in der entsprechenden lokalen Belegungskarte zu akkumulieren.

Als Ergebnis liefert diese Methode eine kompakte Umfeldrepräsentation in Form der Objektmenge \mathcal{T} . Zusätzlich erfolgt die detaillierte und modellfreie Beschreibung der jeweiligen Objektkontur anhand der zugeordneten Belegungskarten.

Um Synergien zwischen den Modulen zu bilden, müssen folgende Voraussetzungen für den modulübergreifenden Datenaustausch erfüllt sein:

- *Zugriff auf Daten der Objektverfolgung für das Belegungskartenmodul:* Die nach Relevanzkriterien gefilterte Objektmenge (siehe Kapitel 6.4.7) wird an das Kartenmodul übertragen, um für jedes Objekt eine lokale Belegungskarte bereitzustellen und zu verwalten.
- *Zuordnung der Sensorrohdaten zu den Objekten:* Entscheidend für die Aktualisierung der OLK ist die Zuordnung der Rohdaten zu den entsprechenden Objekten. Diese Zuordnung wird mit Hilfe der Objekthypothesenbildung (Kapitel 6.3.2) sowie dem Assoziationsschritt in der Objektverfolgung bewerkstelligt. Zunächst sind die Rohdaten um die Hypothesenzugehörigkeit zu erweitern. Erfolgt im nächsten Schritt die Assoziation einer Objekthypothese an ein bestehendes Objekt der Objektverfolgung, lässt sich auf die, dem Objekt zuzuordnenden, Rohdaten schließen.
- *Datenkonsistenz zwischen der Objektmenge und den lokalen Belegungskarten:* Für eine aussagekräftige Objektmodellierung durch die Kopplung der modellgestützten Objektverfolgung und der modellfreien Objektrepräsentation ist es von entscheidender Bedeutung, die Daten beider Umfeldrepräsentationen zueinander konsistent zu

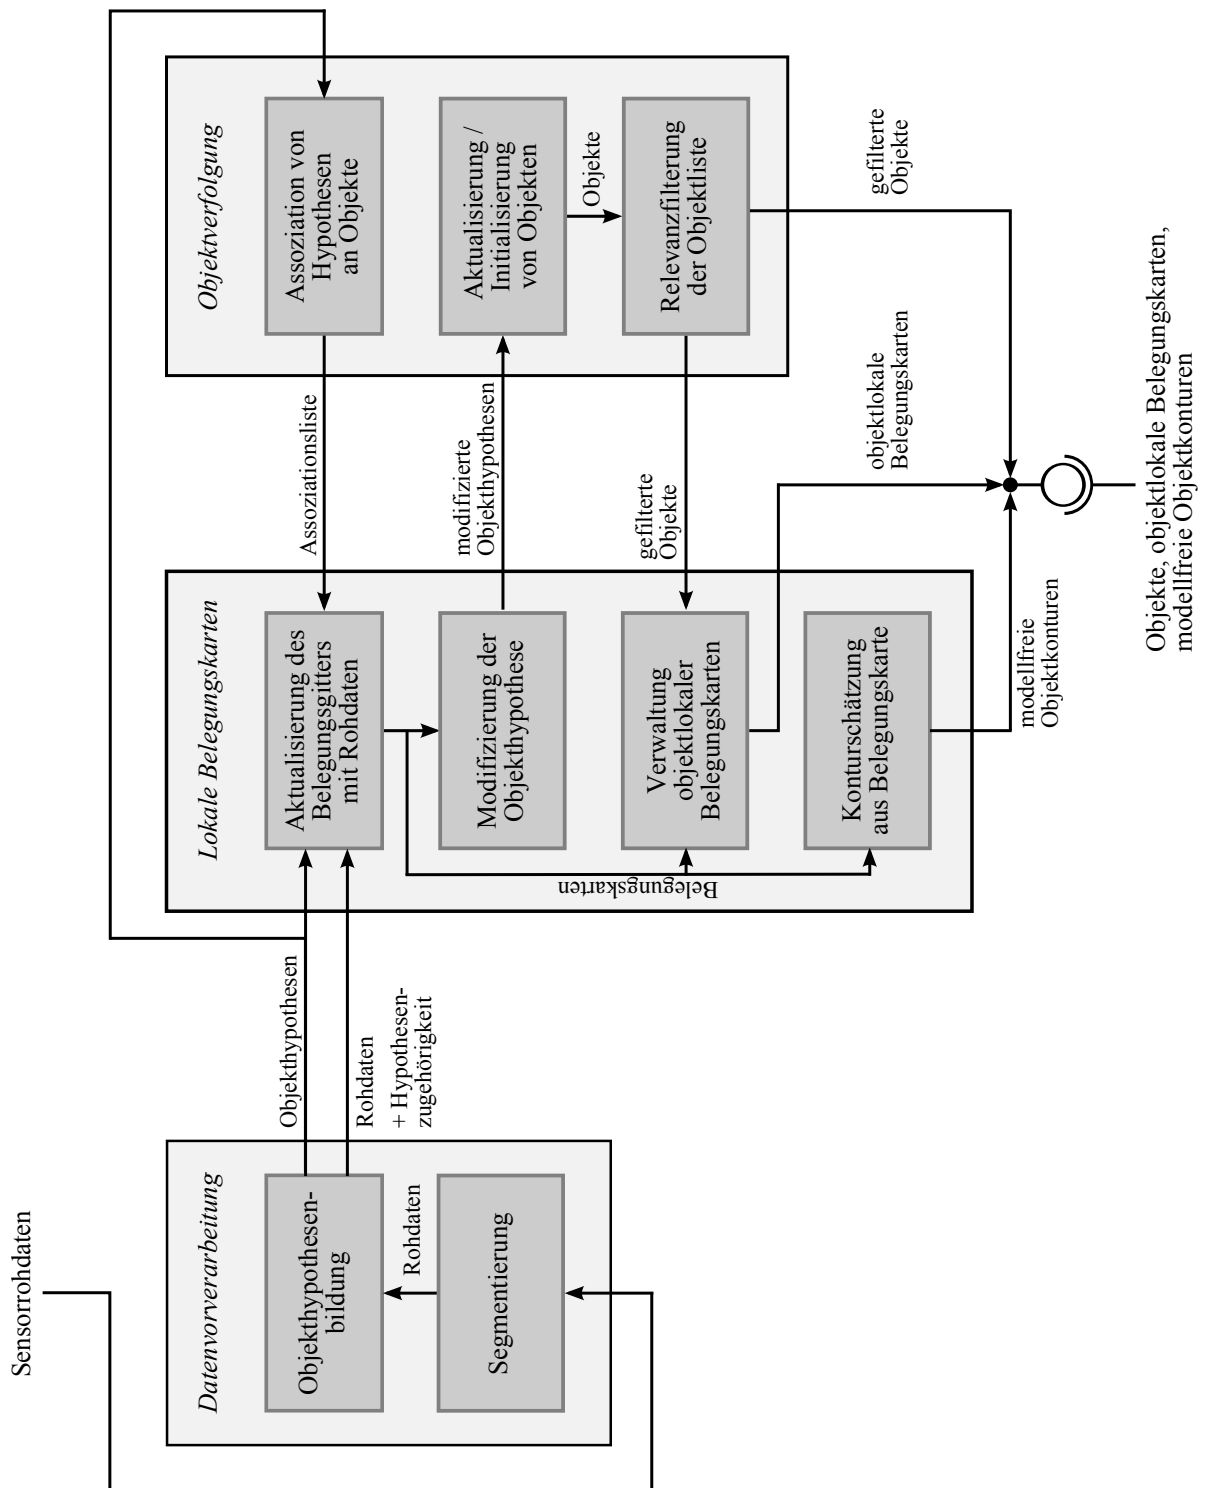


Abbildung 6.1: Architektur der Objektverfolgung mittels objektlokaler Belegungskarten

halten. Dies beinhaltet sowohl die zeitliche Synchronität als auch die inhaltliche Konformität der Daten. Das bedeutet zum einen, dass das Ergebnis der Objektverfolgung sowie das Ergebnis der lokalen Belegungskarten im gleichen Zeittakt verfügbar ist. Zum anderen ist sicherzustellen, dass durch die Objektverwaltung hervorgerufene Änderungen der Objektmenge direkten Einfluss auf die Verwaltung der lokalen Belegungskarte nehmen. Das betrifft beispielsweise das Hinzufügen neuer bzw. das Entfernen veralteter Objekte aus der Objektdatenbank. Dabei ist sicherzustellen, dass neue Belegungskarten initialisiert bzw. veraltete verworfen werden.

- *Integration der lokalen Karteninformation zur Verbesserung der Objektverfolgung:* Die lokalen Belegungskarten akkumulieren die den Objekten zugehörigen Rohdaten über die Zeit. Dadurch ergibt sich ein konsistentes Abbild der Objektkontur unabhängig von vereinzelt auftretenden Teilverdeckungen oder fehlerhaften Sensormessungen. Die lokale Karteninformation ist zur Verbesserung der Zustandsschätzung in die Objektverfolgung zurückzuführen. Dies erfolgt über die in Abbildung 6.1 ausgewiesene Modifikation der Objekthypothesen.

Das angeführte Konzept der Objektverfolgung unter Verwendung von OLK wurde in Aue u. a. (2013b) und Aue u. a. (2013a) vorgestellt. Es bietet die Möglichkeit, die modellfreie Umfelderkennung zur Verbesserung der modellbasierten Objektverfolgung, bei gleichzeitiger Erfassung einer stabilen sowie detaillierten Objektkontur zu nutzen.

6.2 Versuchsaufbau

Für die Evaluierung des vorgestellten Konzepts wurde ein mobiler Versuchsaufbau genutzt. Dieser dient der Datenaufnahme sowie der Demonstration der erarbeiteten Algorithmen. Es folgt die Beschreibung der eingesetzten Hardware sowie der angewandten Sensorschnittstelle.

6.2.1 Hardwarebeschreibung

Der mobile Versuchsaufbau umfasst ein Fahrzeug, welches mit verschiedenen Sensoren zur Umfeld- sowie Eigenbewegungserfassung ausgestattet ist. Die Detektion von Objekten beruht dabei auf Stereokameradaten. Die Stereokamera ist hinter der Windschutzscheibe auf Höhe des Innenspiegels montiert. Tabelle 6.2 fasst die Eigenschaften des Sensors zusammen. Dieser besitzt einen horizontalen Öffnungswinkel von etwa 45° sowie eine Reichweite von ca. 50 m für die Hindernisdetektion. Die Bildauflösung der einzelnen Kameras beträgt 1024×512 pix bei einer Bildrate von etwa 30 bps.

Weiterhin verfügt der Versuchsträger über Sensorik zur Erfassung der Eigenbewegung. Zum einen kann auf eine, durch die Fusion serienmäßiger Raddrehzahlsensoren und zusätzlicher Beschleunigungssensoren erfasste, Eigenbewegung zurückgegriffen werden. Zum anderen verfügt der Versuchsträger über eine hochgenaue Inertialplattform des Typs OXTS RT3000¹ mit einem Differential Global Positioning System (DGPS), welche eine Positionierungs- und Orientierungsgenauigkeit bis zu 0,02 m und $0,1^\circ$ erlaubt. Die hochgenaue

¹Quelle: www.oxts.com/products/rt3000-family, Zugriffsdatum: 17.09.2013

Tabelle 6.2: Eigenschaften des eingesetzten Stereokamerasystems

Eigenschaft	Wert
Bildauflösung	1024×512 pix
Bildrate	30 <i>bps</i>
horizontaler Öffnungswinkel	45°
Reichweite der 3-D Messung	50 m

Inertialplattform findet Anwendung in der Algorithmenreferenzierung der vorliegenden Arbeit, wohingegen die Eigenbewegung, auf Basis der Raddrehzahl- und Beschleunigungssensoren, zur Kompensation der Sensorfahrzeugbewegung beiträgt.

Die Methodik der vorliegenden Arbeit wird mit Hilfe von Stereokameradaten validiert. Dementsprechend basieren die Sensorrohdaten nach Abbildung 6.1 auf zwei parallel aufgenommenen Bildern. Im Folgenden wird die Schnittstelle der Stereokameradaten spezifiziert.

6.2.2 Schnittstellenbeschreibung

Das bereits in Kapitel 2.1.2 vorgestellte Stereokamerasystem besteht aus zwei Kameras, deren Lage zueinander bekannt ist. Aufgrund dieser Anordnung lassen sich aus den einzelnen 2-D Bildpunkten der synchron aufgenommenen Bilder entsprechende 3-D Positionen rekonstruieren. Das dabei entstehende Datenvolumen ist enorm und kann über eine Million 3-D Punkte pro Bildpaar betragen. Dies stellt die Verarbeitung der 3-D Messdaten für Echtzeitanwendungen vor eine große Herausforderung. Um den Anforderungen der Echtzeitdatenverarbeitung gerecht zu werden, sind die Messdaten der Stereokamera zu reduzieren. Gleichzeitig ist durch eine geringe Datenabstraktion ein ausreichender Informationsgehalt für die Folgeanwendung sicherzustellen.

Badino u. a. (2009) zeigen eine Reduktion des Volumens von Stereokameradaten bei einer vergleichsweise geringen Datenabstraktion. Die in dieser Arbeit genutzte Schnittstellenbeschreibung beruht auf dem Ansatz von Badino und wird im Folgenden als *Objektsegmente* bezeichnet.

Abbildung 6.2 zeigt die schematische Darstellung der Objektsegmente im 2-D Bildbereich. Dabei sind die einzelnen Objektsegmente in orange visualisiert und kennzeichnen erhabene Hindernisse². Die Objektsegmentbildung basiert auf den aus beiden Kamerabildern ermittelten Tiefeninformationen. Mit Hilfe eines horizontalen Bildrasters werden mehrere Bildspalten zu einem Rechteck zusammengefasst. Die Breite des Rechtecks ist durch eine konstante Rasterbreite bestimmt. Demgegenüber ist die Höhe des Rechtecks durch die jeweilige Hindernishöhe begrenzt.

Auf Grundlage der Strahlengeometrie und der mittleren Disparität³ lässt sich jedes Objektsegment aus dem Bildbereich in den 3-D Raum übertragen. Für die Modellierung der beiden Kameras als Lochkameramodell und unter der Annahme, dass beide optischen Achsen parallel zueinander ausgerichtet sind, lassen sich die 3-D Kamerakoordinaten (x', y', z')

²erhaben ggü. der Bodenebene

³jedes Objektsegment beinhaltet mehrere Disparitätswerte




Abbildung 6.2: Objektsegmentdarstellung (orange) im 2-D Bildbereich

aus den 2-D Bildkoordinaten⁴ und der mittleren Disparität $(u_1, v_1, disp)$ wie folgt bestimmen:

$$\begin{aligned} z' &= \frac{b_l \cdot f_b}{disp} \\ y' &= \frac{v_1 z'}{f_b} \\ x' &= \frac{u_1 z'}{f_b}. \end{aligned} \quad (6.1)$$

b_l bezeichnet hierbei die Basisbreite des Stereokamerasystems und f_b die Brennweite der beiden Kameras. Anschließend ergibt sich die 3-D Position des Objektsegments in Fahrzeugkoordinaten (x, y, z) durch die homogene Transformation:

$$(x, y, z, 1)^T = \mathbf{T}^{\text{KKS} \rightarrow \text{FKS}} (x', y', z', 1)^T, \quad \mathbf{T}^{\text{KKS} \rightarrow \text{FKS}} = \begin{bmatrix} \mathbf{R} & \mathbf{t} \\ \mathbf{0}^T & 1 \end{bmatrix}. \quad (6.2)$$

\mathbf{R} beschreibt hierbei die Verdrehung von KKS ggü. dem FKS und \mathbf{t} den Verschiebungsvektor des Ursprungs beider Koordinatensysteme.

Abbildung 6.3 stellt die transformierten Objektsegmente (orange) grafisch dar. Die geometrische Form der Objektsegmente ist ebenso wie im Bildbereich durch ein orthogonal zur Bodenebene angeordnetes Rechteck beschrieben. Entgegen der konstanten Breite im Bildbereich variiert die Objektsegmentbreite mit der Entfernung. Die Objektsegmenthöhe entspricht der Höhe des dreidimensionalen Hindernisses.

Für jedes Objektsegment lässt sich die Standardabweichung der einschließenden Disparitätswerte⁵ σ_{disp} berechnen. Die mittlere Disparität bestimmt maßgeblich die Entfernung des Objektsegments. Dementsprechend lässt sich die dargestellte 3-D Positionsunsicherheit entlang des Sichtstrahls durch die Angabe einer minimalen und maximalen Entfernung der 3-D Position modellieren. Diese ist gemäß den Gleichungen (6.1) mit $disp \pm \sigma_{disp}$ zu

⁴linke Kamera mit Index 1 gekennzeichnet

⁵pro Pixel ein Disparitätswert möglich




Abbildung 6.3: Objektsegmentdarstellung (orange) im 3-D Raum

bestimmen.

Abbildung 6.4 zeigt die Objektsegmentschnittstelle im 2-D Bildbereich sowie im 3-D Raum anhand realer Stereokameradaten. In Form eines Startpunkts (blau) mit zugehörigem Vektor (grüne Linie) verfügt die Visualisierung der Objektsegmente im Bildbereich zusätzlich über die Darstellung der gemittelten, horizontalen Flussvektoren. Bei einer Bildauflösung von $1024 \times 512 \text{ pix}$ beträgt die konstante Objektsegmentbreite 4 pix . Abzüglich der nicht deckungsgleichen Randbereiche beider Bilder ergibt sich eine Maximalanzahl N^e von 249 Objektsegmenten pro Bildpaar. Die erreichbare Datenrate der Schnittstelle entspricht mit 15 bps der halben Bildrate der beiden Kameras. Die in den 3-D Raum transformierten Objektsegmente sind in Abbildung 6.4b aus der Vogelperspektive dargestellt und lassen sich nach Definition 6.1 beschreiben.

Definition 6.1. Ein Objektsegment beschreibt eine Messung $\mathbf{y}_i^e = (\mathbf{p}, \varsigma, \mathbf{d}, v)$ mit der Position $\mathbf{p} = (x, y, z) \in \mathbb{R}^3$, der Positionsunsicherheit $\varsigma \in \mathbb{R}$, der Dimension $\mathbf{d} = (b, h) \in \mathbb{R}_+^2$ sowie einem Vertrauensmaß $v \in [0, 1]$.

Jedes Kamerabildpaar liefert die Menge von Objektsegmenten:

$$\mathcal{Y} := \{\mathbf{y}_i^e | i \in [1, N^e]\}. \quad (6.3)$$

Neben der Reduktion des Datenvolumens bietet diese Schnittstellenbeschreibung ggü. einer 3-D Punktwolke auf Pixelniveau einen weiteren Vorteil. Aufgrund der Rasterung im Bildbereich sind die Nachbarn jedes Objektsegments direkt bestimmbar. Ähnlich einem Laser-Scan lassen sich die einzelnen Objektsegmente, beginnend von der linken bis hin zur rechten Bildspalte, durchnummerieren (siehe Abbildung 6.3). Erfolgt die Transformation

der Objektsegmente aus dem 2-D Bildraum in den 3-D Raum, lässt sich die Nachbarschaftsbeziehung aufrecht erhalten. Das Resultat ist eine geordnete Menge von Objektsegmenten \mathbf{y}_i^o .

Ausgehend von der Annahme, dass Objekte im Kamerabild zusammenhängend abgebildet sind, lässt sich hinsichtlich der Segmentierung einzelner Objektsegmente in besonderem Maße von dieser Datenstruktur profitieren. Im Fortlauf dieser Arbeit referenzieren die Begriffe *Rohdaten* bzw. *Sensorrohdaten* die vorgestellten 3-D Objektsegmente.

6.3 Rohdatenvorverarbeitung

Die Rohdatenvorverarbeitung ist ein wichtiger Bestandteil der Datenaufbereitung für die Verfolgung von Objekten. Zunächst sind die Objektsegmente bezüglich ihrer Objektzugehörigkeit zu segmentieren. Anschließend erfolgt eine Abstraktion der gebildeten Segmente zur Generierung von Hypothesen für die Objektverfolgung.

6.3.1 Segmentierung

Aufgabe der Segmentierung von Sensorrohdaten ist die Gruppierung einzelner Messungen anhand ihrer Ähnlichkeiten. Ausgewählte Algorithmen zur Datensegmentierung finden sich bereits in Kapitel 2.4. Dabei zeigt Tabelle 2.3 eine Gegenüberstellung der angeführten Verfahren. Die hierfür verwendeten Kriterien beziehen sich auf die Einsetzbarkeit der Algorithmen für den Bereich der Echtzeitdatenverarbeitung für ADAS.

Abbildung 6.1 zeigt das Konzept der Objektverfolgung basierend auf Sensorrohdaten. Es macht deutlich, dass die Datenvorverarbeitung lediglich einen Teil der Verarbeitungskette darstellt. Um die Echtzeitfähigkeit des gesamten Systems zu bewerkstelligen und die Verarbeitungsdauer geringer als die Datenrate der Sensorschnittstelle zu halten, sind die einzelnen Algorithmen möglichst effizient zu gestalten.


Aufgrund der hohen Anforderung an die Rechenzeit sowie der laserscannerähnlichen Datenstruktur⁶ der Objektsegmente erfolgt die Umsetzung der Rohdatensegmentierung unter Verwendung des Streller-Dietmayer (SD)-Segmentierungsverfahrens gemäß Kapitel 2.4.2. Abbildung 6.5 zeigt das Referenzbild einer zu segmentierenden Szene. Die Sensordaten sind in Form der Objektsegmente (orange) visualisiert. Der SD-Algorithmus nutzt die Nachbarschaftsbeziehung der Sensordatenstruktur sowie einen entfernungsabhängigen Schwellwert (siehe Gleichung (2.12)), um einzelne Objektsegmente \mathbf{y}_i^o anhand ihrer Position \mathbf{p}_i zu Segmenten⁷ zusammenzufassen. Diese sind wie folgt definiert:

Definition 6.2. Ein Segment $\mathcal{S}_l := \{\mathbf{y}_n^o | \mathbf{y}_n^o \in \mathcal{Y}\}$ umfasst eine Menge von Objektsegmenten, die bezüglich der Objektsegmenteigenschaften eine ausreichend große Ähnlichkeit aufweisen.


Die Segmentierung aller Messungen einer Verkehrsszene lässt sich demnach beschreiben durch:

⁶geordnete Datenmenge mit Nachbarschaftsbeziehung

⁷im Folgenden auch als Gruppe oder Gruppierung bezeichnet



(a) Darstellung im 2-D Bildbereich



(b) Darstellung im 3-D Raum aus der Vogelperspektive

Abbildung 6.4: Schnittstelle der Stereokamera - Objektsegmente (orange): Die grünen Linien mit blauem Startpunkt der 2-D Darstellung in (a) kennzeichnen den horizontalen Anteil der optischen Flussvektoren des jeweiligen Objektsegments. Für eine bessere Übersicht sind benachbarte Flussvektoren in der Höhe versetzt. Die konstante Objektsegmentbreite beträgt 2 pix bei einer Bildauflösung von $512 \times 256\text{ pix}$.



Abbildung 6.5: Referenzbild mit Visualisierung der 2-D Objektsegmente (orange)




Abbildung 6.6: Segmentierungsergebnis des SD-Verfahrens (3-D Darstellung aus erhöhter Position)

Definition 6.3. Eine segmentierte Szene ist durch die Menge von Segmenten $\mathcal{S} := \{\mathcal{S}_1, \dots, \mathcal{S}_m\}$ bestimmt, für die gilt: $\bigcup_{l=1}^m \mathcal{S}_l = \mathcal{V} \quad \wedge \quad \mathcal{S}_l \cap \mathcal{S}_k = \emptyset \quad \wedge \quad l \neq k$.

Das Ergebnis der Segmentierung ist in Abbildung 6.6 dargestellt. Die Gruppenzugehörigkeit ist durch verschiedene Farben visualisiert. Es handelt sich hierbei um eine Übersegmentierung der Szene. Das Heck des weißen Fahrzeugs sowie der Transporter (links im Bild) sind gemäß (2.14) in mehrere Segmente \mathcal{S}_l unterteilt. Der Grund dieser Übersegmentierung liegt in der Arbeitsweise des SD-Algorithmus. Dieser vergleicht nach Gleichung (2.11) die jeweils benachbarten Objektsegmente $(\mathbf{y}_i^o, \mathbf{y}_{i+1}^o)$. Ergeben sich durch fehlende Objektsegmentdetektionen Lücken in der Datenstruktur, beendet der Algorithmus die aktuelle Gruppierung und beginnt mit einem neuen Segment. Aufgrund fehlerhafter Disparitäten tritt dieser Effekt für Stereokameradaten ggü. Laserscannerdaten vermehrt auf. Um Übersegmentierungen zu vermeiden, ist der Algorithmus dementsprechend zu modifizieren.

Die Anpassung des SD-Verfahrens für Stereokameradaten erfolgt durch die Einführung eines gleitenden Fensters w_{SD} . Dies ermöglicht die Suche nach ähnlichen Objektsegmenten über eine direkte Nachbarschaft hinaus. Beispielsweise wird für das Objektsegment \mathbf{y}_i^o das Ähnlichkeitsmaß für alle vorangegangenen sowie folgenden Objektsegmente bis einschließlich $\mathbf{y}_{i \pm w_{SD}}^o$ berechnet. So lassen sich Lücken in der Datenstruktur durch nicht besetzte




Abbildung 6.7: Verbessertes Segmentierungsergebnis des SD-Verfahrens durch die Einführung eines gleitenden Fensters w_{SD} für die Ähnlichkeitssuche (3-D Darstellung aus erhöhter Position)

Objektsegmente übergehen und führen nicht zum Abbruch des Segments. Das verbesserte Segmentierungsergebnis ist in Abbildung 6.7 dargestellt. Erneut kennzeichnen die verschiedenen Farben die Zugehörigkeit der einzelnen Objektsegmente \mathbf{y}_i^g zu deren Gruppierung \mathcal{S}_l . Mit Hilfe des gleitenden Fensters w_{SD} erfolgt die Segmentfortführung beider Fahrzeuge und führt somit zu dem gewünschten Segmentierungsergebnis.

6.3.2 Objekthypothesenbildung

Das Aufstellen von Objekthypothesen aus einzelnen Segmenten \mathcal{S}_l ist Teil der modellbasierten Objektverfolgung. Abbildung 6.8 zeigt die Schätzung verschiedener Objekthypothesen (Abbildungen (c)-(e)) am Beispiel einer segmentierten Verkehrsszene (Abbildung (b)). Die Modellierung der Objekthypothese stellt dabei eine Abstraktion der Sensorrohdaten für jedes Segment \mathcal{S}_l dar und lässt sich als Punkthypothese \mathbf{y}_l^P , Quaderhypothese \mathbf{y}_l^B oder orientierte Quaderhypothese \mathbf{y}_l^O beschreiben.

Im Folgenden werden die einzelnen Hypothesenarten näher vorgestellt.

Punkthypothese

Die Punkthypothese ist die einfachste Form der Objekthypothese. Diese ist wie folgt definiert:


Definition 6.4. Eine Punkthypothese ist als Punkt $\mathbf{y}_l^P = (\mathbf{p})$ durch eine Position $\mathbf{p} = (x, y, z) \in \mathbb{R}^3$ beschrieben.

Diese enthält keinerlei Information über die Form des Objekts (siehe Abbildung 4.3a) und ist beispielsweise als Schwerpunktangabe des Segments \mathcal{S}_l mit:

$$\mathbf{y}_l^P = \frac{\sum_{i=1}^n \mathbf{y}_i^g(\mathbf{p})}{n}, \quad \mathbf{y}_i^g \in \mathcal{S}_l \quad (6.4)$$




(a) Referenzbild mit Visualisierung der Objektsegmente (orange)




(b) Segmentierung der Verkehrsszene (Segmentzugehörigkeit durch Farbe gekennzeichnet)



(c) Objekthypothese 1



(d) Objekthypothese 2



(e) Objekthypothese 3

Abbildung 6.8: Objekthypothesenbildung auf Basis einer segmentierten Verkehrsszene: (a) Darstellung in der Bildebene, (b)-(e) Darstellung aus der Vogelperspektive

zu berechnen. $\mathbf{y}_i^o(\mathbf{p})$ bezeichnet hierbei die Position des Objektsegments \mathbf{y}_i^o .

Quaderhypothese

Die Quaderhypothese (siehe Abbildung 4.3d) stellt eine Erweiterung der Punkthypothese um die Segmentdimensionen dar und ist wie folgt definiert:

Definition 6.5. Eine Quaderhypothese ist mit $\mathbf{y}_l^B = (\mathbf{p}, \mathbf{d})$ durch die Position $\mathbf{p} = (x, y, z) \in \mathbb{R}^3$ und die Dimensionen $\mathbf{d} = (l, b, h) \in \mathbb{R}_+^3$ beschrieben.

Neben der Schätzung der Objektposition ist die Objektdimension anhand der Objektsegmente \mathbf{y}_i^o in \mathcal{S}_l zu ermitteln. Ohne die Berücksichtigung von Ausreißern und unter der Annahme, dass sich alle Objekte auf der Bodenebene befinden⁸, lassen sich die Länge l und die Breite b anhand der minimalen und maximalen Objektsegmentpositionen $\mathbf{y}_i^o(\mathbf{p})$ entlang der x - und y -Koordinate mit:

$$\mathbf{y}_l^B(l) = \max(\mathbf{y}_i^o(x)) - \min(\mathbf{y}_i^o(x)), \quad \mathbf{y}_i^o \in \mathcal{S}_l \quad (6.5)$$

$$\mathbf{y}_l^B(b) = \max(\mathbf{y}_i^o(y)) - \min(\mathbf{y}_i^o(y)), \quad \mathbf{y}_i^o \in \mathcal{S}_l \quad (6.6)$$

bestimmen. $\mathbf{y}_i^o(x)$ und $\mathbf{y}_i^o(y)$ bezeichnen die x - bzw. y -Koordinate der Objektsegmentposition. Die Höhe der Hypothese ist durch das höchste Objektsegment aus \mathcal{S}_l mit:

$$\mathbf{y}_l^B(h) = \max(\mathbf{y}_i^o(h)), \quad \mathbf{y}_i^o \in \mathcal{S}_l \quad (6.7)$$

gegeben. $\mathbf{y}_i^o(h)$ bezeichnet dabei die Höhe des i -ten Objektsegments.

Die in Kapitel 4.7 vorgestellte Referenzpunktumschaltung zeigt, dass die Wahl der Positionsangabe einer Objekthypothese hinsichtlich der Schätzung der Objektdynamik von großer Bedeutung ist. Demnach stellt der Schwerpunkt eines Segments bzw. der Mittelpunkt einer Quaderhypothese nur in wenigen Fällen die bestmögliche Positionsangabe dar. Dies betrifft einerseits Segmente mit geringer Anzahl an Messungen⁹ \mathbf{y}_i^o , andererseits Segmente, deren Konturen nicht in Form von Kantenzügen erkennbar sind¹⁰.

Treffen diese beiden Fälle nicht zu, dann ist bei uneingeschränkter Sicht auf das zu messende Objekt der dem Sensor nächstgelegene¹¹ Eckpunkt \mathbf{p}_i^{RP} mit:

$$\mathbf{y}_l^B(\mathbf{p}) = \mathbf{p}_i^{\text{RP}}, \text{ für die gilt: } \min(\text{dist}(\mathbf{p}_i^{\text{RP}})) \wedge \mathbf{p}_i^{\text{RP}} \in \{\mathbf{p}^{\text{RP}_1}, \mathbf{p}^{\text{RP}_3}, \mathbf{p}^{\text{RP}_5}, \mathbf{p}^{\text{RP}_7}\} \quad (6.8)$$

für die Position der Hypothese $\mathbf{y}_l^B(\mathbf{p})$ zu wählen (siehe Abbildung 4.5 Objekt 1). $\text{dist}(\mathbf{p}_i^{\text{RP}})$ beschreibt hierbei den Abstand zwischen der Position des Referenzpunkts i und dem Sensor. Befindet sich ein Objekt an der Grenze des Sensorsichtbereichs (siehe Abbildung 4.5

⁸in diesem Fall ist die z -Koordinate vernachlässigbar

⁹z. B.: gemessenes Objekt befindet sich in großer Entfernung zum Sensor

¹⁰z. B.: Fußgänger

¹¹kleinster Abstand des Punkts zum Sensor

Objekt 2), ist die Positionsangabe nach Gleichung (6.8) jedoch ungeeignet, da die Objektdynamik in diesem Punkt aufgrund der eingeschränkten Sicht nicht vollständig beobachtbar ist. In diesem Fall ist ein Wechsel des Referenzpunkts erforderlich. Dieser lässt sich, bezogen auf das objektlokale Koordinatensystem (siehe Abbildung 4.4 (x' , y')), durch die Addition eines Hebelarms umrechnen. Am Beispiel des Objekts 2 in Abbildung 4.5 ergibt sich dieser für die Umrechnung der Position \mathbf{p}^{RP_5} nach \mathbf{p}^{RP_3} zu:

$$\xi = \left(\zeta_1 \mathbf{y}_l^B(l), \zeta_2 \mathbf{y}_l^B(b), 0 \right)^T, \quad \zeta = (1, 0)^T, \quad \zeta_i \in \{-1, -0.5, 0, 0.5, 1\}. \quad (6.9)$$

Dabei stellt ξ einen additiven Hebelarm, bestimmt durch den Hebelfaktor ζ , der Hypothesenlänge $\mathbf{y}_l^B(l)$ und -breite $\mathbf{y}_l^B(b)$, dar. ζ ist abhängig von den umzurechnenden Referenzpunkten.

Orientierte Quaderhypothese

Die orientierte Quaderhypothese stellt eine Erweiterung von \mathbf{y}_l^B um die Orientierung dar und ist wie folgt definiert:

Definition 6.6. Eine orientierte Quaderhypothese ist mit $\mathbf{y}_l^O = (\mathbf{p}, \mathbf{d}, \psi)$ durch die Position $\mathbf{p} = (x, y, z) \in \mathbb{R}^3$, die Dimensionen $\mathbf{d} = (l, b, h) \in \mathbb{R}_+^3$ sowie die Orientierung $\psi \in [-\pi, \pi]$ beschrieben.

Die Schätzung der Objektorientierung aus Sensorrohdaten gestaltet sich für die Formulierung von Objekthypothesen anspruchsvoll. Aufgrund des fehlenden Wissens bezüglich der tatsächlichen Objektkontur gilt für die Orientierungsschätzung die Annahme, dass sich die Kontur anhand mehrerer Geraden approximieren lässt. Dementsprechend ist bei einem Fahrzeug die Annäherung der Kontur durch einzelne Geraden für das Fahrzeugheck, die Fahrzeugfront sowie der Fahrzeugflanken möglich. Die Richtungsvektoren dieser Geraden erlauben Rückschlüsse auf die Fahrzeugorientierung.

Die Orientierungsschätzung aus Sensorrohdaten stellt ein nichttriviales Problem dar. Zum einen variiert die Positionsschätzung der einzelnen Messungen $\mathbf{y}_i^O(\mathbf{p})$ in einem Segment \mathcal{S}_l aufgrund von Messunsicherheiten. Zum anderen ist die Sicht auf das zu messende Objekt und somit die Erfassung der Objektkontur meist stark beeinträchtigt.

Im Folgenden werden zwei Ansätze der Orientierungsschätzung auf Basis von Objektsegmenten näher vorgestellt.

Analytische Positions- und Orientierungsschätzung Die analytische Schätzung der Objektposition und -orientierung basiert auf einem Rechteck, welches alle Objektsegmente $\mathbf{y}_i^O \in \mathcal{S}_l$ bezüglich ihrer Positionen umschließt. Ziel ist es, den minimalen Flächeninhalt A des Rechtecks durch die Variation der Rechteckorientierung zu bestimmen. Ausgehend von dem initialen Rechteck mit der Orientierung $\psi_l = 0$ sowie der Dimension gegeben durch (6.5) und (6.6), erfolgt eine inkrementelle Änderung von ψ_l , bis A gegen einen Minimalwert konvergiert.

Die Methode zeichnet sich durch eine geringe Berechnungsdauer aus und eignet sich besonders für leicht verrauschte Positionsmessungen. Für stark verrauschte $\mathbf{y}_i^O(\mathbf{p})$ stellt der analytische Ansatz hingegen keine optimale Lösung dar.




Abbildung 6.9: Prinzipdarstellung einer Mischverteilung in einem Segment angenähert durch zwei Normalverteilungen (Vogelperspektive)

Probabilistische Orientierungsschätzung Die Modellierung der Segmente \mathcal{S}_l in Quaderform ist durch die Messung von maximal zwei Seiten des detektierten Objekts bestimmt. Die Beobachtung eines Fahrzeugs kann beispielsweise Messungen des Fahrzeughecks und/oder einer Fahrzeugflanke umfassen. Die Sicht auf alle vier Seiten des Fahrzeugs ist mit der in dieser Arbeit eingesetzten Stereokamera nicht möglich.

Der probabilistische Ansatz zur Bestimmung der Objektorientierung stützt sich auf die Modellierung von Geraden durch diskrete Stützstellen in Form der Objektsegmentpositionen $\mathbf{y}_i^o(\mathbf{p})$. Diese Vorgehensweise basiert auf der Schätzung einer Mischwahrscheinlichkeitsverteilung $p(\mathbf{y}_i^o(x, y))$ für jedes Segment \mathcal{S}_l . $p(\mathbf{y}_i^o(x, y))$ wird hierbei aus zwei mehrdimensionalen Normalverteilungen $p_j \sim \mathcal{N}(\mu_j, \Sigma_j)$, $j \in \{0, 1\}$ mit:

$$p(\mathbf{y}_i^o(x, y)) = \tau p_0(\mathbf{y}_i^o(x, y)) + (1 - \tau) p_1(\mathbf{y}_i^o(x, y)), \quad 0 \leq \tau \leq 1 \quad \wedge \quad \mathbf{y}_i^o \in \mathcal{S}_l \quad (6.10)$$

approximiert. τ beeinflusst das Gewicht der einzelnen Normalverteilungen und $\mathbf{y}_i^o(x, y)$ bezeichnet die x- und y-Position von \mathbf{y}_i^o .

Das Prinzip ist in Abbildung 6.9 beispielhaft dargestellt. Die Anordnung der Messungen \mathbf{y}_i^o zeigt eine typische L-Form-Charakteristik, da das Segment Messwerte zweier benachbarter Fahrzeugseiten beinhaltet.

Mit Hilfe des Expectation Maximization (EM)-Algorithmus erfolgt die Schätzung der Parameter $\theta = (\tau, \mu_0, \mu_1, \Sigma_0, \Sigma_1)$. Dabei arbeitet der EM-Algorithmus iterativ und maximiert die Wahrscheinlichkeitsverteilung $p(\mathbf{y}^o|\theta)$. Er besteht prinzipiell aus folgenden vier Verarbeitungsschritten Bishop und Nasrabadi (2006):

1. Initialisierungsschritt: Bestimme Anfangswerte für θ_k .
2. Expectation-Schritt: Evaluiere $p(\mathbf{x}|\mathbf{y}^e, \theta_k)$.
3. Maximization-Schritt: Evaluiere θ_{k+1} anhand von

$$\theta_{k+1} = \arg \max_{\theta} Q(\theta|\theta_k) \quad (6.11)$$

mit

$$Q(\theta|\theta_k) = \sum_{\mathbf{x}} p(\mathbf{x}|\mathbf{y}^e, \theta_k) \ln p(\mathbf{y}^e, \mathbf{x}|\theta). \quad (6.12)$$

4. Konvergenzprüfung: Unterschreitet die Änderung von θ einen Schwellwert ϵ mit:

$$\|\theta_{k+1} - \theta_k\| < \epsilon, \quad (6.13)$$

endet der Algorithmus. Andernfalls erfolgt die Zuweisung von $\theta_k \leftarrow \theta_{k+1}$. Der Algorithmus wiederholt sich ab dem Expectation-Schritt.

Anhand der geschätzten Parameter θ kann die Ausrichtung des Segments durch die Auswertung der Kovarianzmatrizen \sum_j erfolgen. Die Eigenwertzerlegung von \sum_j liefert die jeweiligen Eigenvektoren \mathbf{x}_j^λ und Eigenwerte λ_j der geschätzten Normalverteilungen. Aus \mathbf{x}_j^λ ist die Orientierung von $p_j(\mathbf{y}_i^e(x, y))$ gemäß:

$$\psi_j = \arctan \left(\frac{\mathbf{x}_j^\lambda(y)}{\mathbf{x}_j^\lambda(x)} \right) \quad (6.14)$$

zu bestimmen. Weiterhin berechnet sich das Vertrauensmaß v_j für ψ_j aus dem Verhältnis der Eigenwerte:

$$v_j = 1 - \gamma_j^2, \quad \gamma_j = \left(\frac{\lambda_j^2}{\lambda_j^1} \right) \quad \wedge \quad (\lambda_j^2 \leq \lambda_j^1). \quad (6.15)$$

Hierbei bestimmt γ_j das Verhältnis zwischen dem kleinen und dem großen Eigenwert der 2-D Normalverteilung $p_j(\mathbf{y}_i^e(x, y))$. Anhand von v_j erfolgt die Selektion der zu schätzenden Orientierung für die Objekthypothese \mathbf{y}_l^O gemäß:

$$\mathbf{y}_l^O(\psi) = \begin{cases} \psi_j & \text{wenn } \max(v_j) > \epsilon_\psi, \\ 0 & \text{wenn } \max(v_j) \leq \epsilon_\psi \end{cases}, \quad 0 \leq \epsilon_\psi \leq 1. \quad (6.16)$$

ϵ_ψ repräsentiert dabei einen Schwellwert, der ein Mindestvertrauensmaß der Orientierungsschätzung vorgibt.

Mit Hilfe von $\mathbf{y}_l^O(\psi)$ erfolgt anschließend die Berechnung der Dimension $\mathbf{y}_l^O(\mathbf{d})$ für das betrachtete Segment \mathcal{S}_l . Dafür sind die Messungen $\mathbf{y}_i^e(\mathbf{p})$ zunächst um $\psi_l = \mathbf{y}_l^O(\psi)$ zu \mathbf{p}_i^* gemäß:

$$\mathbf{p}_i^* = R_z(\psi_l) \mathbf{y}_i^e(\mathbf{p}), \quad R_z(\psi_l) = \begin{pmatrix} \cos \psi_l & -\sin \psi_l & 0 \\ \sin \psi_l & \cos \psi_l & 0 \\ 0 & 0 & 1 \end{pmatrix} \quad (6.17)$$

zu rotieren. Anschließend ist die Objektdimension nach Gleichung (6.5), (6.6) und (6.7) für \mathbf{p}_i^* bestimmbar.

Abbildung 6.10 zeigt eine Gegenüberstellung der Objekthypothesenbildung basierend auf der analytischen (6.10b) und der probabilistischen Orientierungsschätzung (6.10c). Dabei liefert der probabilistische Ansatz eine bessere Orientierung der Objekthypothese als das analytische Verfahren. Weiterhin ist der Abbildung zu entnehmen, dass die Positionsmessungen $\mathbf{y}_i^O(\mathbf{p})$ des Fahrzeughecks stark verrauscht sind und somit keine klare Konturlinie repräsentieren. Für eine verbesserte Schätzung der Position $\mathbf{y}_l^O(\mathbf{p})$ sowie der Dimension $\mathbf{y}_l^O(\mathbf{d})$ ist das Rauschen zu quantifizieren, um die Objekthypothese dementsprechend zu korrigieren.

Probabilistische Positionsbestimmung Die probabilistische Positionsschätzung basiert auf der in Abbildung 6.9 beispielhaft dargestellten Normalverteilung $p_1 \sim \mathcal{N}(\mu_1, \Sigma_1)$. Zunächst werden $\mathbf{y}_l^O(\mathbf{p})$ und μ_1 nach Gleichung (6.17) um den Winkel $\mathbf{y}_l^O(\psi)$ zu \mathbf{p}_i^* und μ_1^* rotiert. Die Position der Hypothese $\mathbf{y}_l^O(\mathbf{p})$ bezieht sich hierbei auf die Objektmitte \mathbf{p}^{RP_9} . Die Korrektur der Objektlänge ergibt sich zu:

$$l^* = \mathbf{y}_l^O(l) - \Delta l, \quad \Delta l = \mu_1^*(x) - \left(\mathbf{p}_i^*(x) - \frac{\mathbf{y}_l^O(l)}{2} \right). \quad (6.18)$$

Δl beschreibt die Differenz zwischen dem aus der Normalverteilung geschätzten Mittelwert in x-Richtung und der auf das Objektheck umgerechneten x-Position. Durch Δl lässt sich die um $\mu_1^*(x)$ korrigierte Länge l^* bestimmen. Anschließend berechnet sich die neue Positionsschätzung¹² anhand der korrigierten Länge l^* zu:

$$\tilde{\mathbf{p}}_l^*(x) = \mu_1^*(x) + \frac{l^*}{2}. \quad (6.19)$$


Die final geschätzte Position der Objekthypothese ergibt sich aus der inversen Rotation von $\tilde{\mathbf{p}}_l^*$ um den Winkel $-\mathbf{y}_l^O(\psi)$ zu $\mathbf{y}_l^O(\mathbf{p}) = \tilde{\mathbf{p}}_l$ nach Gleichung (6.17). Das Ergebnis der verbesserten Schätzung der Objekthypothese ist in Abbildung 6.10d veranschaulicht. Diese zeigt einen erheblich verkürzten Quader ggü. den Hypothesen der Abbildungen 6.10b und 6.10c.

Die in dieser Arbeit zugrunde liegenden Objekthypothesen \mathbf{y}_l^O wurden anhand der probabilistischen Methode zur Orientierungs- und Positionsschätzung erstellt.


6.4 Modellbasierte Zustandsschätzung

Die modellbasierte Zustandsschätzung stellt einen wesentlichen Teil der Objektverfolgung mittels OLK dar (siehe Abbildung 6.1). Diese basiert auf der in Kapitel 4 vorgestellten Methode der Objektbeschreibung und -verfolgung. Deren Aufgabengebiet konzentriert sich auf die Aktualisierung von Objekten durch Sensormessungen. Abbildung 6.11 verdeutlicht


¹² angegeben für den Mittelpunkt des Segments RP_9




(a) Referenzbild mit Visualisierung der Objektsegmente (orange)



(b) Analytische Orientierungs- und Positionsschätzung



(c) Probabilistische Orientierungsschätzung



(d) Probabilistische Orientierungs- und Positionsschätzung

Abbildung 6.10: Vergleich verschiedener Ansätze der Objekthypothesenbildung: Darstellung der Abbildungen (b) - (d) aus der Vogelperspektive

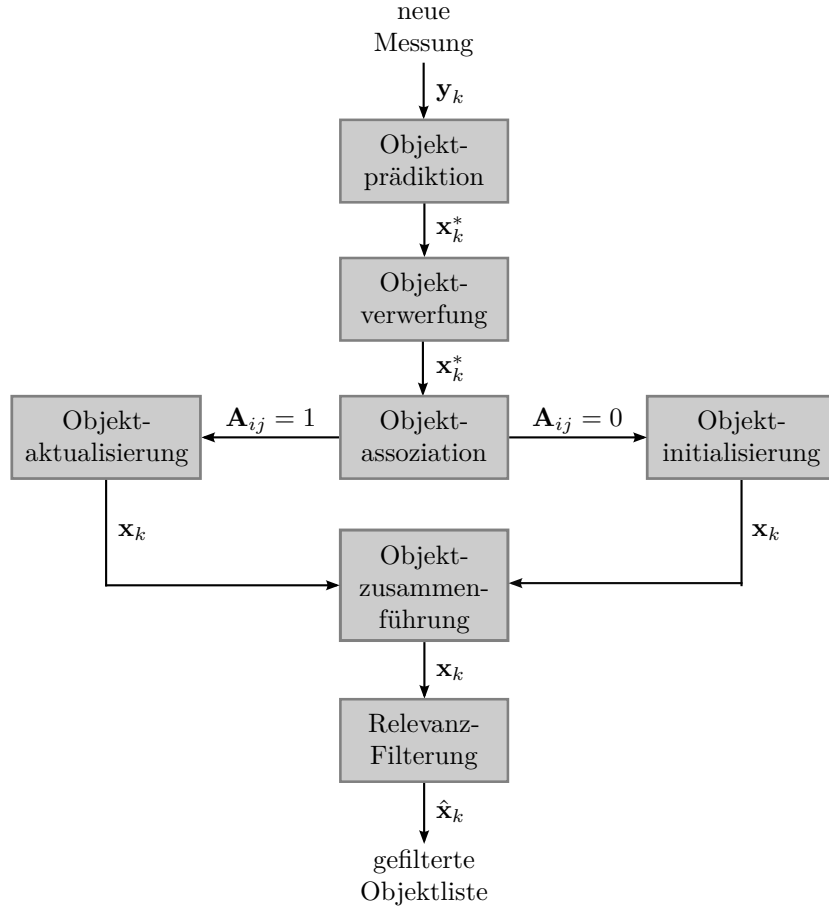


Abbildung 6.11: Übersicht der Zustandsaktualisierung \mathbf{x}_k anhand neuer Messungen \mathbf{y}_k

die Zustandsaktualisierung anhand neuer Messungen \mathbf{y}_k . Der Index k bezeichnet den diskreten Zeitpunkt der Messung und ist in diesem Teilkapitel ausschließlich als Zeitindex zu betrachten.

Folgende Kapitel erläutern die Vorgehensweise der in dieser Arbeit zur Anwendung gebrachten Objektverfolgung.

6.4.1 Messmodell

Der Messvektor ist definiert zu:

$$\mathbf{y}_k = (x, y, \psi, l, b, h)^T. \quad (6.20)$$

Die Kovarianzmatrix \mathbf{R}_k beinhaltet das Messrauschen der einzelnen Größen des Messvektors mit:

$$\mathbf{R}_k = \text{diag} \left(\sigma_x^2, \sigma_y^2, \sigma_\psi^2, \sigma_l^2, \sigma_b^2, \sigma_h^2 \right) \quad (6.21)$$

und bestimmt dadurch die Unsicherheit der Messung \mathbf{y}_k . Das Messrauschen der 2-D Position (σ_x, σ_y) stellt eine Überlagerung verschiedener Unsicherheiten dar. Diese resultieren aus den einzelnen Unsicherheiten der Objektsegmente $(\mathbf{y}_i^o(\varsigma), \mathbf{y}_i^o \in \mathcal{S}_l)$, dem Fehlermaß der Segmentierung $\epsilon_{\mathcal{S}_l}$ sowie der Objekthypothesenbildung $\epsilon_{\mathbf{y}_l^o}$. Da nicht alle Unsicherheiten bekannt sind, werden σ_x und σ_y anhand des quantifizierten Rauschens der Segmente nach Gleichung (6.18) mit Δl approximiert.

σ_ψ ist indirekt abhängig von dem Vertrauensmaß der Orientierungsschätzung nach (6.16) und ergibt sich zu:

$$\sigma_\psi = \begin{cases} 10^\circ & \text{wenn } \psi \neq 0 \\ 45^\circ & \text{wenn } \psi = 0 \end{cases}. \quad (6.22)$$

Die Modellierung von σ_l und σ_b erfolgt stark vereinfacht anhand des maximalen Fehlers für ein durchschnittliches Fahrzeugmodell mit $5m$ Länge und $2m$ Breite. Wird dieser Fehler als 3σ -Intervall angenommen, so ergeben sich die Unsicherheiten $\sigma_l = 1,67m$ und $\sigma_b = 0,67m$. σ_h entspricht der Standardabweichung der Höheninformation $\mathbf{y}_i^o(h)$ aller Objektsegmente der jeweiligen Gruppierung \mathcal{S}_l .

6.4.2 Systemzustand

Der Systemzustand ist gemäß Gleichung (4.2) durch folgende Größen definiert:

$$\mathbf{x}_k = (x, y, v, \psi, \dot{\psi}, l, b, h)^T. \quad (6.23)$$

Demnach ist jedes Objekt durch eine 2-D Position, Geschwindigkeit, Orientierung, Gier-rate, Länge, Breite und Höhe beschrieben. Die Unsicherheit des Systemzustands wird mit Hilfe der Prozesskovarianzmatrix $\mathbf{P}_k^{8 \times 8}$ modelliert.

Die Initialisierung der Objekte für den Zustand \mathbf{x}_0 erfolgt anhand der ersten Messung \mathbf{y}_0 . Die unbekannten Informationen der Objektdynamik $(v, \dot{\psi})$ werden durch entsprechend hohe Unsicherheiten in \mathbf{P}_0 mit $\sigma_v = 100m/s$ und $\sigma_{\dot{\psi}} = 20^\circ/s$ modelliert.

6.4.3 Zustandsprädiktion

Um die Objektzustände auf den Aufnahmezeitpunkt der Messung zu präzisieren, ist nach Gleichung (2.53) der Zustandsübergang mit \mathbf{F}_k zu modellieren. Das in dieser Arbeit verwendete Bewegungsmodell entspricht dem CTRV-Modell nach Kapitel 4.3.3. Die Bestimmung des prädisierten Objektzustands \mathbf{x}_k^* erfolgt nach Gleichung (4.10).

Die Kovarianzmatrix \mathbf{Q} bildet die Unsicherheit des modellierten Zustandsübergangs mit:

$$\mathbf{Q} = \text{diag} \left(0, 0, \sigma_{\dot{\psi}}^2 \Delta t^3, \sigma_a^2 \Delta t^2, \sigma_{\dot{\psi}}^2 \Delta t^2 \right) \quad (6.24)$$

ab. Die maximale Beschleunigung eines Objekts wird mit $a = 9,81 \frac{m}{s^2}$ als 3σ -Grenze angenommen. Dementsprechend ergibt sich eine Standardabweichung der Beschleunigung

von $\sigma_a = 3,27 \frac{m}{s^2}$. Die Standardabweichung der Winkelbeschleunigung wird mit $\sigma_{\ddot{\psi}} = 3 \frac{^\circ}{s^2}$ approximiert.

6.4.4 Zustandsaktualisierung

Die Zustandsaktualisierung erfolgt durch die Integration einer neuen Messung \mathbf{y}_k in den Systemzustand. Dafür ist nach Gleichung (2.55) der prädizierte Zustand \mathbf{x}_k^* mit Hilfe der Messmatrix \mathbf{G} in den Messraum zu überführen. Die Messmatrix resultiert aus dem Messvektor \mathbf{y}_k und dem Zustandsvektor \mathbf{x}_k zu:

$$\mathbf{G} = \begin{pmatrix} 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 \end{pmatrix}. \quad (6.25)$$

Die Aktualisierung von \mathbf{x}_k und \mathbf{P}_k wird anhand des in Kapitel 2.5.3 vorgestellten Kalman-Filter-Zyklus durchgeführt.

6.4.5 Objektverwerfung

Um die Lebensdauer von Objekten zu begrenzen, ist das Verwerfen veralteter Objekte erforderlich. Das Entfernen nicht bestätigter Objekte reduziert die Menge aller Objekte \mathcal{T} mit:

$$\mathbf{x}_i \notin \mathcal{T} \quad \wedge \quad (t - t_{\mathbf{x}_i}) > \epsilon_{\Delta t}. \quad (6.26)$$

Liegt der letzte Aktualisierungszeitpunkt $t_{\mathbf{x}_i}$ eines Objekts \mathbf{x}_i durch eine Messung \mathbf{y}_j länger als $\epsilon_{\Delta t}$ zurück, wird das Objekt aus der Menge entfernt. t entspricht in diesem Zusammenhang der aktuellen Zeit. Die Objektverwerfung der in dieser Arbeit zugrunde liegenden Objektverfolgung basiert auf dem Schwellwert $\epsilon_{\Delta t} = 0,5$ s.

6.4.6 Objektzusammenführung

Die Notwendigkeit zur Zusammenführung von Objekten entsteht durch fehlende Assoziationen $\mathbf{A}_{ij} = 0$ der Messungen \mathbf{y}_j zu den Objekten \mathbf{x}_i . Diese fehlenden Assoziationen resultieren in neu initialisierten Objekten \mathbf{x}_0 , deren Zustandsschätzung den bereits erfassten Objekten gleicht. Dadurch erhöht sich die Objektanzahl N , einhergehend mit einem Anstieg der Verarbeitungszeit der Objektaktualisierung. Um die Rechenzeit möglichst gering zu halten, ist die Verfolgung ähnlicher Objekte zu vermeiden.

Die Ähnlichkeit der Objekte \mathbf{x}_i und \mathbf{x}_j lässt sich beispielsweise über den euklidischen Abstand (2.10) oder den Mahalanobisabstand (2.9) bestimmen. Unterschreitet die Ähnlichkeit den Schwellwert ϵ_d mit $\text{dist}(\mathbf{x}_i, \mathbf{x}_j) < \epsilon_d$, erfolgt die Zusammenführung von \mathbf{x}_i und \mathbf{x}_j . Hierzu existieren verschiedene, bezüglich ihrer Komplexität zu unterscheidende, Lösungsansätze Matzka und Altendorfer (2009).

Tabelle 6.3: Kriterien der Relevanzfilterung

Eigenschaft	Schwellwerte
Varianz der Position x	$\sigma_x^2 < 0,3 \text{ m}^2$
Varianz der Position y	$\sigma_y^2 < 0,3 \text{ m}^2$
Objektaktualisierungen	$\kappa > 5$
Objektlänge	$0,1 \text{ m} \leq \mathbf{x}_l \leq 6,0 \text{ m}$
Objektbreite	$1,0 \text{ m} \leq \mathbf{x}_b \leq 3,0 \text{ m}$

Um die Verarbeitungszeit der Objektverfolgung gering zu halten, erfolgt in dieser Arbeit keine rechenaufwendige Zusammenführung ähnlicher Objekte. Stattdessen wird das jüngere der beiden Objekte mit:

$$\mathbf{x}_j \notin \mathcal{T} \quad \wedge \quad \kappa_j < \kappa_i \quad (6.27)$$

aus der Menge aller Objekte \mathcal{T} verworfen. Dabei bezeichnet κ_i die Anzahl der Aktualisierungen von \mathbf{x}_i durch aufeinander folgende Messungen. Der Schwellwert beträgt $\epsilon_d = 1 \text{ m}$.

6.4.7 Relevanzfilterung

Nicht alle in \mathcal{T} enthaltenen Objekte sind für Folgeanwendungen gleich bedeutsam. Die Relevanzfilterung (siehe Abbildung 6.11) bietet die Möglichkeit, bestimmte Objekte $\hat{\mathbf{x}}_k$ aus \mathcal{T} zu extrahieren. In Bezug auf die Anwendung von OLK nach Abbildung 6.1 ist \mathcal{T} anhand der in Tabelle 6.3 genannten Kriterien zu filtern. Ziel ist die Extraktion stabiler Objekte mit begrenzter Objektausdehnung aus der Menge aller verfolgten Objekte \mathcal{T} .

6.5 Objektlokale Belegungskarten

Die OLK dient der Erweiterung der modellbasierten Objektbeschreibung und enthält zusätzliche, modellfreie Konturinformationen für jedes aus der Objektverfolgung extrahierte Objekt. Abbildung 6.1 veranschaulicht die Kernaufgaben der lokalen Belegungskarten. Neben der Kartenverwaltung ist die Zellaktualisierung durch Rohdaten sowie die Modifikation der Objekthypothesen durch Karteninformationen zu bewerkstelligen.

6.5.1 Konzept

Das Konzept der OLK basiert auf der Abbildung der Objektkontur in einer dem Objekt zugewiesenen Belegungskarte. Dabei prägt sich die Kontur in Form belegter Zellen durch die Integration von Sensormessungen des Objekts in der Belegungskarte aus. Wie bereits in Kapitel 5.6 angeführt, eignet sich die modellfreie Umfeldmodellierung zum Erfassen statischer Hindernisse. Um die Belegungskarte für dynamische Objekte nutzbar zu machen, erfolgt die Verankerung des Objekts mit der zugewiesenen Belegungskarte. Abbildung 6.12 stellt das Konzept der lokalen Belegungskarte grafisch dar. Jedes Objekt (gelb) wird




Abbildung 6.12: Konzept der objektlokalen Belegungskarte: zugehöriges Objekt (gelb) gibt die Position und Orientierung der Karte vor, belegte Zellen (rot), der Ankerpunkt \mathbf{p}_A kennzeichnet die starre Verbindung zwischen der Karte und dem Objekt

auf der lokalen Belegungskarte fixiert. Der Ankerpunkt \mathbf{p}_A beschreibt dabei die Position des Objekts im lokalen Koordinatensystem der Karte. Die lokale Belegungskarte wird entsprechend der Objektbewegung mitgeführt und ausgerichtet. Die zeitlich integrierten Messungen initiieren belegte Bereiche in der Karte, dargestellt durch rote Zellen, die eine zweidimensionale Objektkontur abbilden. Die objektlokale Belegungskarte definiert sich wie folgt:

Definition 6.7. Eine objektlokale Belegungskarte K^O beschreibt eine 2-D Belegungskarte K (siehe Definition 5.1), welche zusätzlich über einen Ankerpunkt $\mathbf{p}_A = (dx, dy) \in \mathbb{R}^2$, eine Pose $\mathbf{x}^p = (x_0, y_0, \psi)$ mit $(x_0, y_0) \in \mathbb{R}^2, \psi \in [-\pi, \pi]$ sowie eine eindeutige Identifikationsnummer $id \in \mathbb{N}$ verfügt.

Die in Kapitel 6.2.2 vorgestellte Rohdatenschnittstelle der Stereokamera beinhaltet neben der Position ebenfalls die Höheninformation $\mathbf{y}_i^g(h)$ der Objektsegmente. Erlaubt die

Kartenstruktur die Speicherung der Höheninformation pro Zelle¹³, lässt sich ebenfalls der Höhenverlauf des Objekts modellieren.

Für die optimale Abbildung der Objektkontur setzt dieses Konzept eine zeitlich konsistente Objekterscheinung voraus. Bezugnehmend auf die Erfassung von Verkehrsteilnehmern des Fahrzeugumfelds ist diese Annahme zutreffend, da sich die Gestalt der einzelnen Verkehrsteilnehmer unwesentlich über die Zeit verändert.

6.5.2 Kartenverwaltung

Die Aktualisierung der OLK erfolgt in zwei Schritten. Zunächst wird die Kartenpose $K_m^O(\mathbf{x}^p)$ entsprechend der Objektpose $\mathbf{x}_j(x, y, \psi)$ erneuert. Anschließend findet die Aktualisierung des Zellinhalts $K_m^O(z_{i,j})$ durch neue Sensormessungen statt. Die Kartenverwaltung hat dabei die Aufgabe, die zeitliche Synchronität sowie die inhaltliche Konformität der Objekte mit den zugeordneten lokalen Belegungskarten sicherzustellen. Die Erneuerung der Kartenpose erfolgt nach Abbildung 6.1 durch das Empfangen einer nach Relevanzkriterien gefilterten Objektmenge \mathcal{T}^* . Ein Abgleich mit der bestehenden Menge der objektlokalen Belegungskarten:

$$\mathcal{K} := \{K_1^O, \dots, K_n^O\} \quad (6.28)$$

gewährleistet die Datenkonformität. Demnach wird die Pose des zugehörigen Objekts \mathbf{x}_j in $K_m^O(\mathbf{x}^p)$ übernommen, wenn gilt:

$$\exists id_{\mathbf{x}_j} \text{ für die gilt: } id_{\mathbf{x}_j} = K_m^O(id), \quad K_m^O \in \mathcal{K} \quad \wedge \quad \mathbf{x}_j \in \mathcal{T}^*. \quad (6.29)$$

$id_{\mathbf{x}_j} \in \mathbb{N}$ bezeichnet dabei die Identifikationsnummer des Objekts \mathbf{x}_j . Findet sich gemäß:

$$\nexists K_m^O(id) \text{ für die gilt: } K_m^O(id) = id_{\mathbf{x}_j}, \quad K_m^O \in \mathcal{K} \quad \wedge \quad \mathbf{x}_j \in \mathcal{T}^* \quad (6.30)$$

keine OLK zu dem empfangenen Objekt \mathbf{x}_j , wird \mathcal{K} um die Karte K_m^O erweitert. Der initiale Ankerpunkt $K_m^O(\mathbf{p}_A)$ der Belegungskarte befindet sich, entsprechend der Darstellung in Abbildung 6.12, im Abstand von der halbierten Objektlänge $\frac{\mathbf{x}_j(l)}{2}$ in x-Richtung und der Hälfte der Objektbreite $\frac{\mathbf{x}_j(b)}{2}$ in y-Richtung des Kartenzentrums.

Gilt weiterhin:

$$\nexists id_{\mathbf{x}_j} \text{ für die gilt: } id_{\mathbf{x}_j} = K_m^O(id), \quad K_m^O \in \mathcal{K} \quad \wedge \quad \mathbf{x}_j \in \mathcal{T}^*, \quad (6.31)$$

erfolgt das Verwerfen von K_m^O aus der Menge aller lokalen Belegungskarten \mathcal{K} .

Für die Aktualisierung des Zellinhalts $K_m^O(z_{i,j})$ mittels neuer Sensormessungen \mathbf{y}_n^g ist eine Registrierung der Messungen auf der Belegungskarte notwendig. Die Registrierung sowie die Zellaktualisierung werden im Folgenden spezifiziert.

¹³auch als 2.5-D Karte bezeichnet

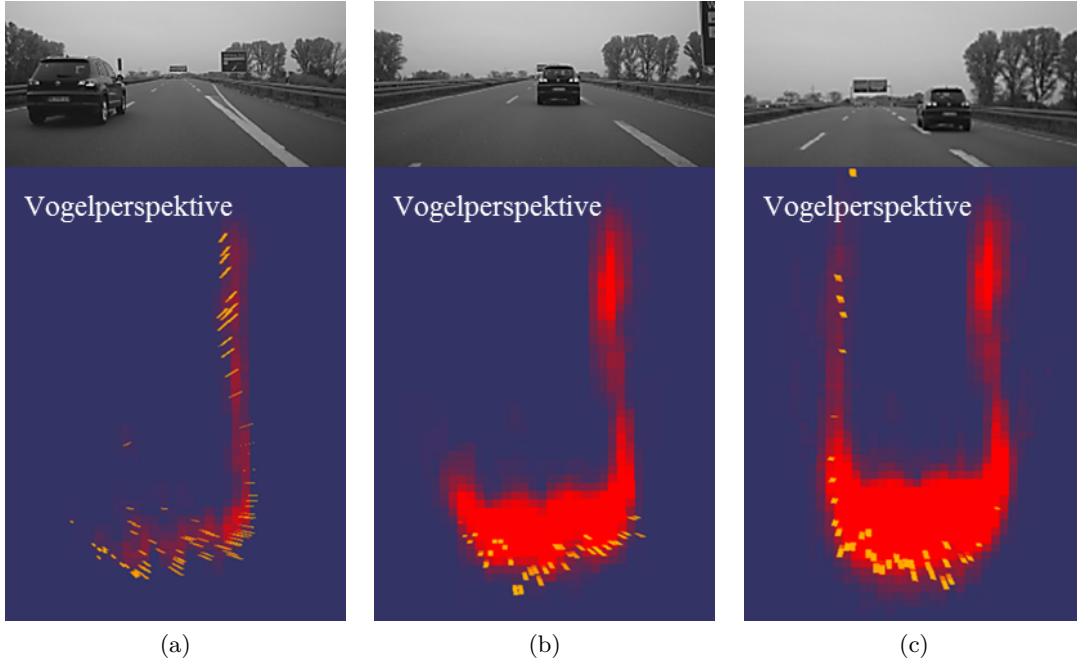


Abbildung 6.13: Darstellung der Registrierungsproblematik von Sensorrohdaten \mathbf{y}_n^e (orange) und den zugehörigen lokalen Belegungskarten $K_m^O(z_{i,j})$ (rote Zellen)

6.5.3 Registrierung von Sensorrohdaten

Die Registrierung von Sensorrohdaten verfolgt das Ziel, die optimale Übereinstimmung zwischen den Objektsegmenten \mathbf{y}_n^e ($\mathbf{y}_n^e \in \mathcal{S}_l$) und dem Karteninhalt $K_m^O(z_{i,j})$ zu finden. Das Ergebnis stellt eine optimale Kartenpose $\tilde{\mathbf{x}}^p$ dar, die unter Verwendung des inversen Sensormodells zur Integration der Messungen in die Belegungskarte führt. Diese Aufgabe stellt ein nichttriviales Problem für die Anwendung objektlokaler Belegungskarten dar. Abbildung 6.13 zeigt die Schwierigkeit der Registrierung verschiedener Segmente sowie unterschiedlich ausgeprägter Belegungskarten. Zum einen sind die einzelnen Messungen \mathbf{y}_n^e in ihrer Position stark verrauscht (6.13a), zum anderen führt dieses Rauschen zu großflächig belegten Bereichen in K_m^O (6.13b, 6.13c). Die Suche nach einer direkten Übereinstimmung von \mathbf{y}_n^e mit $K_m^O(z_{i,j})$ liefert daher keine eindeutige Lösung. Demnach ist die optimale Kartenpose $\tilde{\mathbf{x}}^p$ anhand der aktuellen Belegungsinformationen $K_m^O(z_{i,j})$ sowie der aktuellen Messungen \mathbf{y}_n^e bestmöglich zu schätzen. Die Genauigkeit von $\tilde{\mathbf{x}}^p$ wirkt sich direkt auf die Qualität von K_m^O aus.

Die in dieser Arbeit angewandte Schätzung von $\tilde{\mathbf{x}}^p$ basiert auf dem *Importance Sampling Verfahren*. Der Algorithmus beinhaltet Teilschritte des in Kapitel 2.5.3 vorgestellten SIR Filters. Hierbei wird die Verteilung von $\tilde{\mathbf{x}}^p$ durch eine Menge von Partikeln $\mathcal{X} := \{\mathbf{x}_1^p, \dots, \mathbf{x}_{M_X}^p\}$ repräsentiert. Die Ziehung der verschiedenen Kartenposen¹⁴ \mathbf{x}_j^p er-

¹⁴auch als Partikel bezeichnet

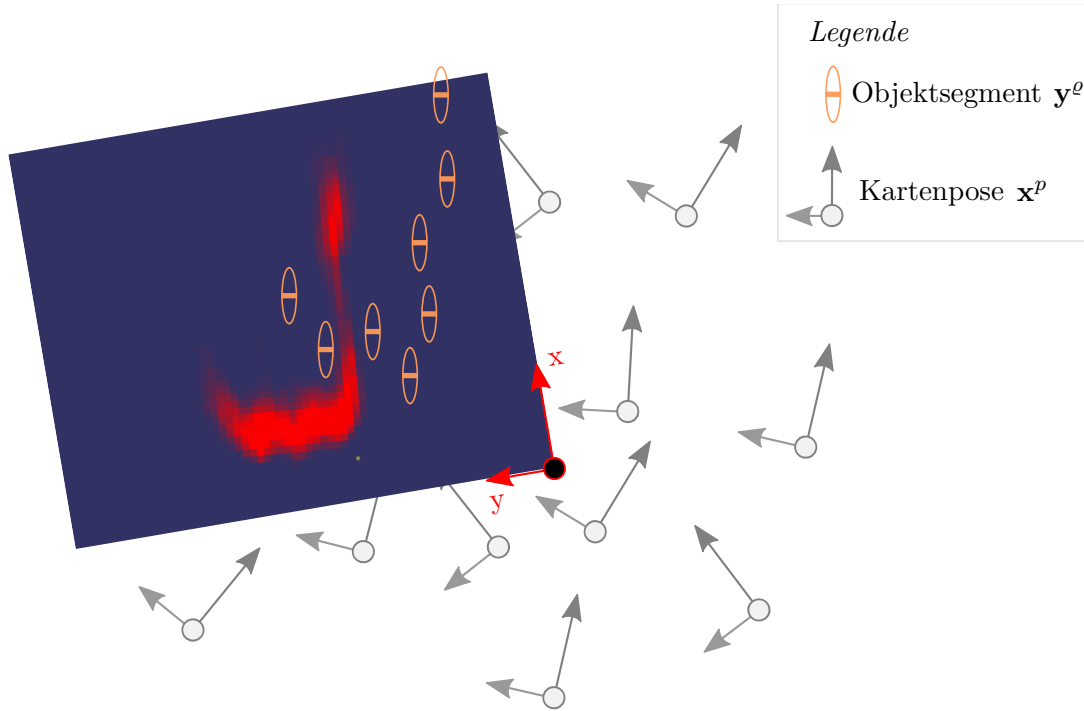


Abbildung 6.14: Beispielhafte Darstellung der Registrierung eines Segments auf einer objektlokalen Belegungskarte (Vogelperspektive)

folgt anhand der Normalverteilung:

$$\mathcal{N}(\mathbf{x}_{init}^p, \mathbf{C}), \quad \mathbf{x}_{init}^p = \left(\left[\mathbf{y}_l^O(x) - K_m^O(dx) \right], \left[\mathbf{y}_l^O(y) - K_m^O(dy) \right], \mathbf{y}_l^O(\psi) \right)^T, \quad (6.32)$$

wobei $\mathbf{y}_l^O(x, y, \psi)$ der Objekthypothesenpose des Segments \mathcal{S}_l entspricht. $K_m^O(dx, dy)$ beschreibt die 2-D Koordinaten des Ankerpunkts \mathbf{p}_A . Demnach werden von $\mathcal{N}(\mathbf{x}_{init}^p, \mathbf{C})$ verschiedene Kartenposen gezogen, deren Mittelwert der initialen Objekthypothesenpose entspricht.

Die Kovarianzmatrix \mathbf{C} bestimmt die Streuung der Partikelmenge \mathcal{X} . \mathbf{C} ist sensorspezifisch, ihre Bestimmung erfolgt empirisch. Dieser Verarbeitungsschritt wird im Folgenden auch als *Sampling* bezeichnet.

Abbildung 6.14 veranschaulicht das Ergebnis des Samplingschritts anhand der Kartenposen \mathbf{x}_j^p , mittels verschiedener Koordinatensysteme. Aus Gründen der Übersichtlichkeit ist lediglich eine lokale Belegungskarte für ein Koordinatensystem (rot) visualisiert.

Nach dem Aufstellen der Partikelmenge \mathcal{X} wird das Gewicht jedes Partikels \mathbf{x}_j^p gemäß:

$$w_j = \frac{p(\mathbf{x}_j^p | \mathbf{y}_n^o)}{p(\mathbf{x}_j^p)} \quad (6.33)$$

bestimmt. $p(\mathbf{x}_j^p | \mathbf{y}_n^o)$ resultiert aus der Bewertung der Deckungsgleichheit der einzelnen

Messungen \mathbf{y}_n^e mit den in der Karte enthaltenen belegten Zellen $z_{i,j}$:

$$p(\mathbf{x}_j^p | \mathbf{y}_n^e) = \sum_{\mathbf{y}_n^e} \sum_{z_{i,j}} p(z_{i,j}) \nu_n, \quad \mathbf{y}_n^e \in \mathcal{S}_l \quad \wedge \quad z_{i,j} \in K. \quad (6.34)$$

ν_n bezeichnet das Gewicht der Messung \mathbf{y}_n^e . Der zu wertende Bereich von \mathbf{y}_n^e wird um die Positionsunsicherheit des Objektsegments erweitert. Abbildung 6.14 hebt diese Fläche durch die jeweilige Ellipse hervor. Alle Zellen $z_{i,j}$ innerhalb dieser Ellipse werden für die Berechnung nach Gleichung (6.34) berücksichtigt.

$p(\mathbf{x}_j^p)$ gibt die Wahrscheinlichkeit der Pose von der ursprünglich gezogenen Normalverteilung $\mathcal{N}(\mathbf{x}_{init}^p, \mathbf{C})$ an.

Die gesuchte Kartenpose $\tilde{\mathbf{x}}^p$ zur Aktualisierung der lokalen Belegungskarte K_m^O mit \mathbf{y}_n^e lässt sich anschließend aus der Partikelmenge \mathcal{X} sowie der Menge der zugehörigen Gewichte $\mathcal{W} := \{w_j | j \in [1, M^X]\}$ bestimmen. Das Schätzen einer Normalverteilung aus \mathcal{X} und \mathcal{W} ermöglicht die Bestimmung des Mittelwerts $\mu_{\mathcal{X}} = (x, y, \psi)^T$ mit $(x, y) \in \mathbb{R}^2, \psi \in [-\pi, \pi]$ aller Partikel für die 2-D Position sowie die Orientierung. Dieser entspricht mit $\tilde{\mathbf{x}}^p = \mu_{\mathcal{X}}$ der optimalen Kartenpose.

Alternativ kann $\tilde{\mathbf{x}}^p$ anhand der Pose mit dem höchsten Gewicht bestimmt werden. Für Stereokameradaten erweist sich jedoch die Methode der Mittelwertbildung als robuster ggü. der Methode des höchsten Gewichts.

Die Integration der ersten Sensormessungen \mathbf{y}_n^e in K_m^O stellt für die Registrierung eine Besonderheit dar, da keine Belegungsinformationen in der Karte enthalten sind. In diesem Fall entspricht die optimale Pose mit $\tilde{\mathbf{x}}^p = \mathbf{x}_{init}^p$ der initialen Pose, sodass keine Schätzung anhand des Importance Sampling Verfahrens erfolgt.

6.5.4 Zellaktualisierung

Die Aktualisierung der Kartenzellen $K_m^O(z_{i,j})$ durch neue Messungen \mathbf{y}_n^e setzt die in Kapitel 6.5.3 bestimmte optimale Kartenpose $\tilde{\mathbf{x}}^p$ voraus. Die Positionsangaben für \mathbf{y}_n^e und $\tilde{\mathbf{x}}^p$ beziehen sich hierbei auf das Fahrzeugkoordinatensystem (FKS). Für die Kartenaktualisierung sind diese in das Kamerakoordinatensystem (KKS)¹⁵ zu überführen.

Abbildung 6.15 veranschaulicht den Prozess der Integration neuer Sensormessungen. Zunächst erfolgt die Transformation der optimalen Kartenposition $\tilde{\mathbf{x}}^p(x, y)$ in das KKS mit:

$$\left({}^{\text{KKS}}\tilde{\mathbf{x}}^p(x, y)^T, 1 \right)^T = \mathbf{T}^{\text{FKS} \rightarrow \text{KKS}} \left(\tilde{\mathbf{x}}^p(x, y)^T, 1 \right)^T. \quad (6.35)$$

Um das inverse Sensormodell nach Kapitel 5.3 für die Zellaktualisierung anwenden zu können, sind die Messungen \mathbf{y}_n^e mit:

$$\left({}^{\text{KKS}}\mathbf{y}_n^e(\mathbf{p})^T, 1 \right)^T = \mathbf{T}^{\text{FKS} \rightarrow \text{KKS}} \left(\mathbf{y}_n^e(\mathbf{p})^T, 1 \right)^T \quad (6.36)$$

in das KKS zu überführen. Dabei erfolgt eine differenzierte Betrachtung des zu aktuali-

¹⁵Sensorkoordinatensystem




Abbildung 6.15: Aktualisierung des Zellinhalts der objektlokalen Belegungskarte $K_m^O(z_{i,j})$ anhand neuer Messungen \mathbf{y}_n^e : Für die Anwendung des inversen Sensormodells sind \mathbf{y}_n^e und $\tilde{\mathbf{x}}^p$ von dem Fahrzeug- in das Kamerakoordinatensystem zu überführen.




Abbildung 6.16: Gegenüberstellung der Kartenausprägung (rot) des einfachen (a) und des erweiterten (b) Sensormodells zur Integration der Messungen \mathbf{y}_n^e in K_m^O am Beispielobjekt Fahrzeug (Vogelperspektive)

sierenden Bereichs von $K_m^O(z_{i,j})$. Messungen von dem Sensor zugewandten Objektseiten sind von Messungen orthogonal zum Sensor verlaufender Objektflächen zu unterscheiden. Abbildung 6.13 zeigt die Ausprägung einer OLK zu drei unterschiedlichen Zeitpunkten. Die Messungen \mathbf{y}_n^e für die Aktualisierung des Zellinhalts der Karte stammen von einem vorausfahrendem Fahrzeug. Das Sensorfahrzeug befindet sich in Folgefahrt und konnte durch den lateralen Versatz zu dem beobachteten Objekt neben den Messungen der Fahrzeugrückseite ebenfalls Messungen der Fahrzeugflanke in die Belegungskarte integrieren. Die zeitlich aufeinander aufbauenden Bilder (a)-(c) verdeutlichen, dass Messungen der Fahrzeugrückseite im Mittel häufiger auftreten als Messungen der Fahrzeugflanke. Um dieses Ungleichgewicht zu kompensieren, erfolgt für Messungen der Objektlängsseite die Aktualisierung eines größeren Bereichs als für Messungen des Fahrzeughecks. Der Vorgang wird im Folgenden als *erweitertes Sensormodell* bezeichnet.

In Abbildung 6.15 sind die unterschiedlichen Aktualisierungsbereiche durch eine weiße Umrandung des jeweiligen Objektsegments gekennzeichnet. Abbildung 6.16 stellt eine objektlokale Belegungskarte ohne (a) und eine mit differenzierten Aktualisierungsbereich (b) gegenüber. Die Abbildung veranschaulicht die Wirksamkeit des erweiterten Sensormodells für die Ausprägung geschlossener Konturverläufe der Objektlängsseiten.

6.5.5 Konturschätzung

Ein wesentlicher Vorteil von OLK ist die modellfreie Repräsentation der Objektform (siehe Abbildung 6.16b). Die objektspezifische Konturinformation ist für nachfolgende Verarbeitungsschritte effizient aus $K_m^O(z_{i,j})$ zu bestimmen. Der Algorithmus 1 zeigt die Extraktion einer Menge von 2-D Konturpunkten $\mathbf{p} = (x, y) \in \mathbb{R}^2$ aus K_m^O . Die Konturpunktmenge ist definiert zu:

$$\mathcal{P}^K := \{\mathbf{p}_l | l \in [1, N_K]\}. \quad (6.37)$$

N_K beschreibt hierbei die aktuelle Anzahl der Konturpunkte.

Die Suche nach gesättigten Zellen in K_m^O findet prinzipiell von den Randbereichen hin zum Zentrum der Karte statt. Zunächst erfolgt die Bestimmung der äußeren 2-D Positionen der ermittelten Zellen. Anschließend werden diese 2-D Punkte der Konturpunktmenge \mathcal{P}^K hinzugefügt.

Algorithmus 1: Extraktion der Konturpunkte \mathcal{P}^K der Belegungskarte K^O

Daten : Lokale Belegungskarte K^O der Größe $n \times n$, Schwellwert der Belegungswahrscheinlichkeit ϵ_p

Ergebnis : Menge aller Konturpunkte \mathcal{P}^K

```
// Iteriere über alle vier Seiten von  $K^O$ 
for  $k \leftarrow 0$  to 3 do
    // Iteriere entlang der k-ten Kartenseite
    for  $i \leftarrow 0$  to  $n$  do
        // Finde die erste gesättigte Zelle der i-ten Reihe
        for  $j \leftarrow 0$  to  $n/2$  do
            // Bestimme Belegungswahrscheinlichkeit der Zelle
             $p(z_{i,j}) \leftarrow \text{BestimmeZellBelegungswahrscheinlichkeit}(K_m^O(z_{i,j}))$ ;
            // Verifiziere ob die  $p(z_{i,j})$  den Schwellwert übersteigt
            if  $p(z_{i,j}) > \epsilon_p$  then
                // Bestimme äußeren 2-D Punkt der Zelle
                 $\mathbf{p}_l \leftarrow \text{BestimmeAussenPunktderZelle}(i, j)$ ;
                // Erweitere Punktmenge um den Konturpunkt
                 $\mathbf{p}_l \in \mathcal{P}^K$ ;
                break;
            end
        end
    end
end
end
```

Abbildung 6.17 stellt das Ergebnis grafisch dar. Die Objektkontur ist als Punktmenge \mathcal{P}^K (grüne 2-D Punkte) visualisiert, deren Auflösung der Diskretisierung der lokalen Belegungskarte entspricht.

Im Folgenden werden Mechanismen zur Verbesserung der Qualität der lokalen Belegungskarte vorgestellt.

6.5.6 Kartenmechanismen

Um die OLK hinsichtlich der Verbesserung der Objektverfolgung zu optimieren, kommen zwei Mechanismen zum Einsatz. Zum einen erfolgt die Zentrierung der Objektkontur auf




Abbildung 6.17: Ergebnis der Objektkonturextraktion in Form der Punktmenge \mathcal{P}^K (grüne 2-D Punkte) auf Basis einer 2-D objektlokalen Belegungskarte (Vogelperspektive)

der Belegungskarte, zum anderen kompensiert ein Verfallswert das in der Karte abgebildete Messrauschen der Sensorrohdaten. Beide Mechanismen werden im Folgenden näher erläutert.

Zentrierung der Objektkontur

Sobald die Objektkontur eine vorgegebene Größe überschreitet, folgt die Zentrierung des belegten Bereichs in der Belegungskarte. Dies ermöglicht eine optimale Nutzung der Kartengröße. Demzufolge lässt sich der gesamte Belegungsereich der Karte für das Abbilden der Objektkontur nutzen und ist nicht durch die initiale Vergabe des Ankerpunkts $K_m^O(\mathbf{p}_A)$ nach Kapitel 6.5.2 limitiert.

Abbildung 6.18 zeigt das Ergebnis der Zentrierung der Objektkontur. Die Konturposition der Abbildung 6.18a resultiert hierbei aus einer initial stark verkürzten Objektlänge, sodass $K_m^O(\mathbf{p}_A)$ unweit des Kartenzentrums platziert wird. Für Objekte größeren Ausmaßes kann dies zum Verlust wertvoller Konturinformationen führen, da sich einzelne Messungen u. U. außerhalb der Belegungskarte befinden und somit für die Zellaktualisierung unberücksichtigt bleiben. Abbildung 6.18b hingegen zeigt die Zentrierung der erfassten Konturinformation. Das optimale Einsetzen des zur Verfügung stehenden Kartenbereichs minimiert den Informationsverlust durch unberücksichtigte Messungen.

Zeitliches Abklingen

Das Positionsrauschen der Messungen $\mathbf{y}_n^e(\mathbf{p})$ führt in Form von großflächigen Bereichen gesättigter Zellen zu einer Verbreiterung der Objektkanten in K_m^O . Eine Abklingkonstante bewirkt eine Schärfung der Objektkontur, indem die Belegungswahrscheinlichkeit einzelner Zellen mit:

$$p_k(z_{i,j}) = p_{k-1}(z_{i,j}) - \epsilon_\tau, \quad z_{i,j} \in K \quad \wedge \quad \mathbf{p}_l \notin \mathcal{P}_{k-1}^K, \quad (6.38)$$




Abbildung 6.18: Gegenüberstellung der Belegungskarte ohne (a) und mit (b) Zentrierung der Objektkontur: Das weiße Quadrat kennzeichnet die äußere Grenze des Belegungsgitters, der gelbe Punkt repräsentiert den Ankerpunkt \mathbf{p}_A , grüne Punkte markieren die Objektkontur \mathcal{P}^K (Vogelperspektive).

um die Konstante ϵ_τ reduziert wird. ϵ_τ ist sensor- sowie anwendungsspezifisch und wird empirisch bestimmt. Von dem Verfall ausgeschlossen sind Zellen, deren äußere Position \mathbf{p}_l in der Punktmenge der aktuellen Objektkontur \mathcal{P}_{k-1}^K enthalten ist. Daraus resultierend bleibt \mathcal{P}^K zeitlich konsistent. Bereits extrahierte Konturverläufe in \mathcal{P}^K werden bewahrt. Abbildung 6.19 zeigt die Veränderung der Zellausprägung mit zeitlichem Abklingen ggü. der Zellausprägung ohne zeitliches Abklingen (siehe Abbildung 6.17). Erkennbar sind die aufgrund der Abklingkonstanten mit weniger gesättigten Zellen repräsentierten Objektlängsseiten. Dementgegen weist der hintere Teil des Objekts lediglich geringe Unterschiede auf, da die Häufigkeit der Messungen in diesem Bereich sehr hoch ist. Somit nimmt ϵ_τ lediglich marginalen Einfluss auf die Belegungswahrscheinlichkeit dieser Zellen.

6.5.7 Parameterdiskussion

Die Ausprägung der OLK lässt sich anhand mehrerer Einstellungen parametrieren. Beispielsweise führt eine Verkleinerung der Zellauflösung zu einer detaillierteren Erfassung der Konturverläufe. Dies ist jedoch mit einer Zunahme der Verarbeitungsdauer verbunden. Um mögliche Anforderungen an die Verarbeitungszeit sowie die Detaillierung der Konturinformationen einzuhalten, ist die Größe der Zellen auf die entsprechende Anwendung abzustimmen.

Gleiches gilt für die Wahl der Partikelanzahl M^χ für die Registrierung der Messungen auf der lokalen Belegungskarte (siehe Kapitel 6.5.3). Eine hohe Anzahl an Partikeln führt zu einer besseren Schätzung der optimalen Kartenpose $\tilde{\mathbf{x}}^p$, einhergehend mit der Zunahme der Rechenzeit.

Das inverse Sensormodell ermöglicht für die Aktualisierung einzelner Kartenzellen $z_{i,j}$, die

Beeinflussung des Konvergenzverhaltens der Belegungswahrscheinlichkeit. Hierfür ist der Betrag für die Aktualisierung von freien sowie von belegten Bereichen variierbar. Vergrößert sich beispielsweise der Betrag für die Messwertintegration belegter Bereiche, konvergiert die Belegungswahrscheinlichkeit der Zellen durch weniger Messungen \mathbf{y}_n^e . Darüber hinaus bestimmt die Größe des Aktualisierungsbereichs der Objektsegmente (siehe Abbildung 6.15) die Anzahl der für die Messwertintegration erfassten Zellen. Eine Überschneidung mehrerer Aktualisierungsbereiche bewirkt somit eine Superposition der Messungen in der Belegungskarte. Das Resultat ist ein schnelleres Konvergieren der durch mehrere Messungen überlagerten Zellen.

Die Abklingkonstante ϵ_τ schärft die Objektkontur. ϵ_τ unterbindet die dauerhafte Ausprägung großflächiger Bereiche gesättigter Zellen. Ein hoher Betrag für ϵ_τ führt zu schnellerem Abklingen der Belegungswahrscheinlichkeit. Einerseits wird dadurch das Positionsrauschen von \mathbf{y}_n^e stärker kompensiert. Andererseits verzögert dies die Bestimmung der Konturverläufe \mathcal{P}^K anhand der Belegungsinformation.

6.5.8 Anreicherung der Objekthypothesen mit Karteninformationen

Um den Informationsgewinn der OLK für die Objektverfolgung nutzen zu können, erfolgt das Überschreiben einzelner Merkmale der Objekthypothesen \mathbf{y}_l^O mit zugehörigen Karteninformationen. Dabei lassen sich folgende Eigenschaften aus K_m^O für die Anreicherung von \mathbf{y}_l^O ableiten:

- *Position:* Die Registrierung der Sensorrohdaten nach Kapitel 6.5.3 liefert die optimale Pose $\tilde{\mathbf{x}}^p$ für die bestmögliche Integration der Messungen \mathbf{y}_n^e in K_m^O . Mit $\mathbf{y}_l^O(x) = (\tilde{\mathbf{x}}^p(x) + K_m^O(dx))$ und $\mathbf{y}_l^O(y) = (\tilde{\mathbf{x}}^p(y) + K_m^O(dy))$ kann die verbesserte Positionsschätzung der Objekthypothese \mathbf{y}_l^O erfolgen.
- *Orientierung:* Analog zur Positionsverbesserung aus $\tilde{\mathbf{x}}^p$ ist die Orientierung mit $\mathbf{y}_l^O(\psi) = \tilde{\mathbf{x}}^p(\psi)$ anhand der optimalen Pose zu modifizieren.
- *Abmaße:* Die Objektlänge und -breite in Form des Rechteckmodells ist in der Menge aller Konturpunkte \mathcal{P}^K enthalten. Der Algorithmus 2 beschreibt die Extraktion der Objektlänge l und -breite b aus \mathcal{P}^K . Dies erlaubt die Änderung der Dimension der Objekthypothesen $\mathbf{y}_l^O(l) = l$ und $\mathbf{y}_l^O(b) = b$. Das weiße Rechteck in Abbildung 6.19 visualisiert das Ergebnis der Längen- und Breitenschätzung. Weiterhin lässt sich die Messunsicherheit der zeitlich stabilisierten Länge σ_l und Breite σ_b für die Methoden der modellbasierten Objektverfolgung reduzieren. Erlaubt die Kartenstruktur das Ablegen der Höheninformation (siehe Abbildung 6.20) für jede Zelle $K_m^O(z_{i,j})$, lässt sich die Höhe der Objekthypothese mit $\mathbf{y}_l^O(h) = \max(h_{i,j})$ aus dem Maximum der Höhe aller Zellen bestimmen.

Prinzipiell gilt es, eine Verschlechterung der Objekthypothese \mathbf{y}_l^O zu vermeiden. Aus diesem Grund ist eine Einschwingphase der OLK abzuwarten, bevor eine Anreicherung von \mathbf{y}_l^O mit Informationen aus K_m^O stattfindet.

Algorithmus 2: Rechteckschätzung anhand der Konturpunktmenge \mathcal{P}^K

Daten : Menge aller Konturpunkte \mathcal{P}^K

Ergebnis : Rechtecklänge l , Rechteckbreite b

// Erstelle Histogramm für die Koordinaten (x, y) anhand von \mathbf{p}_l in \mathcal{P}^K

$histX \leftarrow \text{ErstelleHistogramm}(\mathbf{p}_l(x));$

$histY \leftarrow \text{ErstelleHistogramm}(\mathbf{p}_l(y));$

// Extrahiere die zwei größten Maxima des Histogramms

$maximaX \leftarrow \text{MaximaHistogramm}(histX, 2);$

$maximaY \leftarrow \text{MaximaHistogramm}(histY, 2);$

// Bestimme Rechteckdimension aus Differenz der Maxima

$(l, b) \leftarrow \text{BestimmeDieDimension}(maximaX, maximaY);$




Abbildung 6.19: Ergebnis der Objektkonturextraktion in Form der Punktmenge \mathcal{P}^K (grüne 2-D Punkte) auf Basis einer 2-D objektlokalen Belegungskarte: Der weiße Rahmen entspricht der Abstraktion von \mathcal{P}^K auf das Rechteckmodell (Vogelperspektive).




Abbildung 6.20: Objektlokale Belegungskarte mit Höheninformation für jede Zelle: Die Punktmenge der Objektkontur \mathcal{P}^K ist dargestellt in grün. Der weiße Rahmen entspricht der Abstraktion von \mathcal{P}^K auf das Rechteckmodell. Der gelbe Punkt symbolisiert den Ankerpunkt \mathbf{p}_A des Objekts auf der Belegungskarte (3-D Perspektive).

Kapitel 7

Validierung

Dieses Kapitel erörtert quantitative sowie qualitative Ergebnisse der Objektverfolgung mittels OLK. Die Validierung verdeutlicht die Herausforderungen der Objektverfolgung anhand von Stereokameradaten. Folgende Probleme gilt es zu bewältigen:

- Starkes Entfernungsrauschen der Sensorrohdaten
- Lückenhafte Objekterfassung aufgrund fehlender Disparitäten
- Teilverdeckung der Objekte

Weiterhin wird der Nutzen von OLK für die Schätzung der Objektkontur diskutiert. Hierbei liegt der Fokus auf einer modellfreien Konturbeschreibung bewegter Objekte. Zunächst wird das Funktionsprinzip der Referenzierung dynamischer Objekte erläutert.

7.1 Referenzierung dynamischer Objekte

Die Referenzierung dynamischer Objekte erfolgt mit Hilfe einer hochgenauen Ortungslösung basierend auf DGPS. Dazu werden ein Hasen-¹ sowie ein Sensorfahrzeug mit einer Inertialplattform (siehe Kapitel 6.2.1) ausgestattet. Abbildung 7.1 skizziert das Prinzip der Referenzierung. Unter Verwendung der jeweiligen Inertialplattform erfolgt eine globale Bestimmung der Referenzgrößen *3-D Position*, *Orientierung*, *Geschwindigkeit* und *Beschleunigung*.

Die beiden Referenzsysteme sind zeitlich synchronisiert. Dies ermöglicht die Vergleichbarkeit der einzelnen Referenzgrößen zwischen verschiedenen Fahrzeugen. Mit einer Taktrate von 25 Hz erfolgt eine WLAN-Übertragung der Referenzdaten des Hasenfahrzeugs an das Sensorfahrzeug.

Das im Sensorfahrzeug verbaute Stereokamerasystem ermöglicht lediglich die Bestimmung relativer Objektgrößen. Um eine Vergleichbarkeit dieser relativen Sensordaten mit den Referenzdaten herzustellen, sind die global ermittelten Referenzsignale beider Fahrzeuge in relative Größen umzurechnen.

Neben den bestimmten Referenzdaten stehen für die Validierung ebenfalls die *Länge*, *Breite* und *Höhe* des Hasenfahrzeugs zur Verfügung.

Die folgende Validierung basiert auf der vorgestellten Methode der Referenzierung dynamischer Objekte.

¹zu beobachtendes Fahrzeug zur Referenzierung der Objektverfolgung

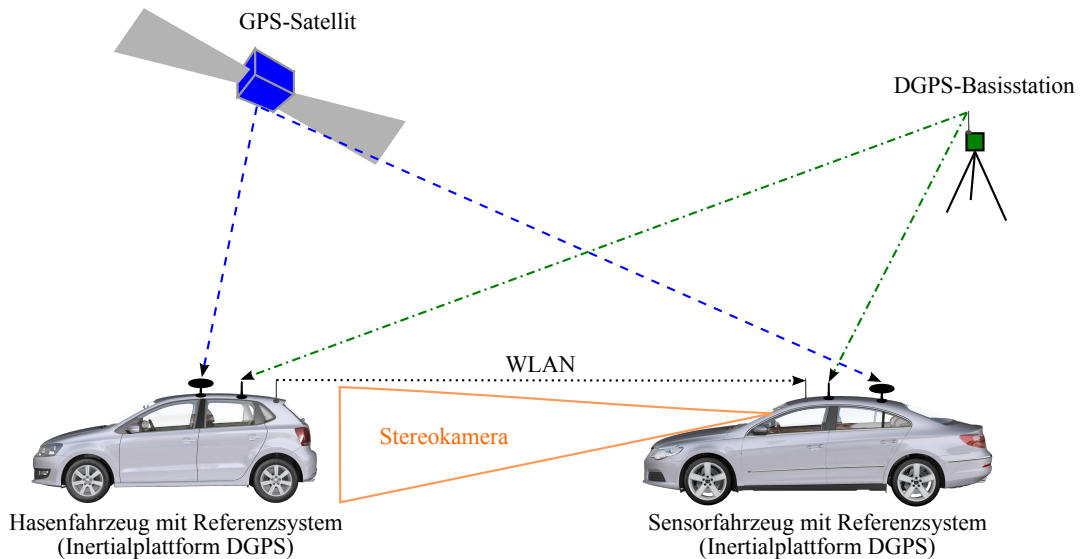


Abbildung 7.1: Prinzipskizze für Referenzierung dynamischer Objekte

7.2 Verbesserung der modellbasierten Objektverfolgung

Das vorgestellte Konzept der Objektmodellierung mit OLK verfolgt das Ziel, die modellbasierte Objektverfolgung (siehe Kapitel 4) zu verbessern. Die Validierung untersucht die Auswirkungen der Kombination modellbasierter und modellfreier Methoden der Umfeldfassung für folgende Objekteigenschaften: *2-D Position*, *Geschwindigkeit*, *Orientierung* und *Abmaße*.

2-D Position Für die Objektposition ergeben sich keine nennenswerten Unterschiede zwischen den Ergebnissen der Objektverfolgung mit und ohne OLK. Dies ist auf die bereits verbesserte Positionsbestimmung (siehe Kapitel 6.3.2) mit Hilfe der probabilistischen Positionsschätzung der Objekthypothesen \mathbf{y}_l^O zurückzuführen. Weiterhin bieten die stark übersättigten Bereiche² von K_m^O (siehe Abbildung 6.19) nur einen geringen Informationsgehalt für die Verbesserung der Positionsbestimmung.

Für die referenzierte Sequenz beträgt der mittlere Fehler der Positionsschätzung in x-Richtung -0,03 m mit einer Standardabweichung von 0,34 m und in y-Richtung 0,03 m mit einer Standardabweichung von 0,22 m.

Geschwindigkeit Die Schätzung der Objektgeschwindigkeit erfolgt für positionsgebende Sensoren³ anhand der zeitlichen Änderung der Positionsmessungen. Da OLK in Kombination mit Stereokameradaten keinen nennenswerten Einfluss auf die Positionsschätzung nehmen, zeigt sich für die Schätzung der Objektgeschwindigkeit ein ähnliches Verhalten.

²hervorgerufen durch das Positionsrauschen der Rohdaten

³z. B.: Stereokamera oder Laserscanner




Abbildung 7.2: Vergleich der Orientierungsschätzung für die Objektverfolgung mit und ohne OLK

Orientierung Abbildung 7.2 stellt das Ergebnis der Orientierungsschätzung des referenzierten Objekts dar. Die beiden untersuchten Signale folgen dem prinzipiellen Verlauf der Referenzvorgabe. Die Orientierungsschätzung mit OLK bietet im Vergleich zu der Orientierungsschätzung ohne OLK geringere Abweichungen zur Referenz. Entscheidend für die Stabilisierung der Orientierungsschätzung ist die Ausprägung der Längsinformation in K_m^O . Die Objektkontur bildet sich durch stetiges Integrieren neuer Messungen in der Belegungskarte ab. Nach einer Einschwingphase von etwa 5 s erfolgt die Anreicherung der Objekthypothesen mit Karteninformationen (siehe Abbildung 7.4 roter und grüner Signalverlauf entfernt sich voneinander). Dies wirkt sich positiv auf die Schätzung der Objektorientierung aus.

Abmaße Ein weiterer Vorteil der OLK für die modellbasierte Objektverfolgung liegt in der Stabilisierung der Objektdimension. Die Abbildungen 7.3 und 7.4 zeigen neben dem konstanten Referenzsignal den Verlauf der geschätzten Objektbreite sowie der Objektlänge für die Signale mit und ohne OLK. Erkennbar ist ein identisches Ergebnis der beiden Schätzungen in der Anfangsphase der betrachteten Sequenz. Solange die Objektkontur nicht ausreichend in der lokalen Belegungskarte K_m^O ausgeprägt ist, erfolgt keine Modifikation der Objekthypothesen zur Verbesserung der Objektverfolgung.

Nach dem Einschwingen von K_m^O erweist sich die Schätzung der Objektbreite mit OLK stabiler als ohne OLK. Auffällig ist in diesem Fall das vermeintliche Überspringen nach etwa 15 s sowie das Unterschätzen der Objektbreite nach etwa 30 s. Die Zellgröße der eingesetzten OLK beträgt 0,1 m. Das Abtasten der Objektbreite erfolgt deshalb ebenfalls in




Abbildung 7.3: Vergleich der Breitenschätzung für die Objektverfolgung mit und ohne OLK

0,1 m-Schritten, wodurch die Schätzung der Breite zwischen 1,80 m und 1,90 m (um die Referenz von 1,86 m) variiert.

Die Schätzung der Objektlänge zeigt eine deutliche Verbesserung der Objektverfolgung mit ggü. ohne OLK. Für den ausgewählten Datensatz gilt, dass die Objektlänge entgegen der Objektbreite nicht zu jedem Zeitpunkt beobachtbar ist. Dadurch unterliegt die Längenschätzung ohne OLK starken Schwankungen. Dementgegen verhält sich die Schätzung mit OLK robust und konvergiert gegen den konstanten Referenzwert.

7.3 Starkes Entfernungsrauschen der Sensorrohdaten

Das Entfernungsrauschen der Sensorrohdaten nimmt direkten Einfluss auf die Ausprägung der Objektkontur in K_m^O . Für starkes Rauschen bilden sich größere Bereiche gesättigter Zellen aus. Ist hingegen das Entfernungsrauschen der Messungen gering, zeichnet sich eine klare Objektkontur in K_m^O ab. Die Höhe des Rauschens wird in diesem Zusammenhang von mehreren Faktoren bestimmt.

Mit zunehmender Objektentfernung gilt für die Positionsbestimmung der Stereokameradaten (2.3) eine nichtlineare Zunahme des Entfernungsfehlers. Weiterhin ist die Genauigkeit der Kamerakalibrierung ausschlaggebend für eine präzise Entfernungsbestimmung der Messungen \mathbf{y}_n^e . Aufgrund des optischen Messprinzips wirkt sich die Beeinträchtigung der Sichtverhältnisse negativ auf die Genauigkeit der Stereokameradaten aus. Im Besonderen stellen nasse Fahrbahnen eine große Herausforderung für eine genaue Positionsbestimmung




Abbildung 7.4: Vergleich der Längenschätzung für die Objektverfolgung mit und ohne OLK


einzelner Messungen $\mathbf{y}_n^g(\mathbf{p})$ dar.

Abbildung 7.5 veranschaulicht die Auswirkungen einer nassen Fahrbahnoberfläche auf die Objektverfolgung mittels Stereokameradaten. Abbildung 7.5a zeigt das Referenzbild der Verkehrsszene. Die für die Objektverfolgung relevanten Messungen sind durch ein gelbes Rechteck hervorgehoben. Abbildung 7.5b stellt die segmentierten Einzelmessungen anhand einer 3-D Ansicht⁴ dar. Die gelbe Ellipse umschließt die dem Objekt zuzuordnenden Messungen \mathbf{y}_n^g . Die Zugehörigkeit von \mathbf{y}_n^g zu den einzelnen Segmenten \mathcal{S}_l ist durch verschiedenen Farben gekennzeichnet. Die Messungen des Fahrzeugs erstrecken sich in der Länge über einen Bereich von etwa 7 m und in der Breite von etwa 2 m. Auffällig ist dabei die Streuung der Objektsegmentposition $\mathbf{y}_n^g(\mathbf{p})$ des Fahrzeughecks über eine Entfernung von ca. 3 m. Aufgrund der nassen Fahrbahnoberfläche wird hinter dem Fahrzeug Wasser aufgewirbelt. Die Gischt beeinträchtigt die Sicht auf das Objekt und führt zu einer Verschlechterung der Disparitätswerte der Stereokameradaten. Der Fehler der Disparitätsbestimmung wirkt sich erheblich auf die Entfernungsschätzung von \mathbf{y}_n^g aus. Das Resultat ist eine enorme Streuung der einzelnen Objektsegmentpositionen $\mathbf{y}_n^g(\mathbf{p})$ des Fahrzeughecks. Zu große Abstände zwischen den Messungen führen hierbei zu einer Übersegmentierung des Objekts⁵.


Abbildung 7.5c zeigt den Einfluss der Übersegmentierung auf die modellbasierte Objektverfolgung. Anstelle einer Objekthypothese zur Aktualisierung des beobachteten Objekts werden zwei Hypothesen \mathbf{y}_1^O und \mathbf{y}_2^O aus den Sensorrohdaten extrahiert. Diese unter-

⁴aus erhöhter Position von hinten rechts auf das Objekt blickend


⁵das Objekt ist in zwei Segmente unterteilt



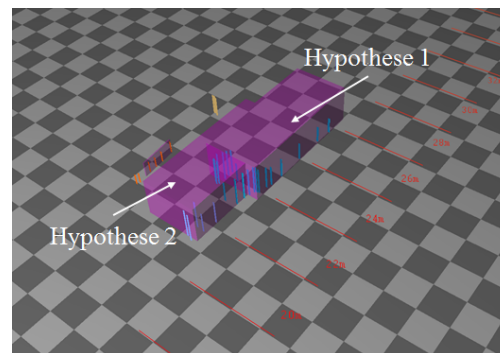
(a)



(b)



(c)



(d)

Abbildung 7.5: Einfluss einer nassen Fahrbahn auf die Objektverfolgung mittels Stereokameradaten: (a) - Referenzbild mit Visualisierung der Objektsegmente (orange) und horizontalen optischen Flussvektoren (grün), (b) - 3-D Darstellung der segmentierten Objektsegmente (Segmentzugehörigkeit ist durch verschiedene Farben gekennzeichnet), (c) - Objekthypothesenschätzung ohne OLK (in Quaderform), (d) - Objekthypothesenschätzung mit OLK (in Quaderform)




Abbildung 7.6: Abweichung der Positionsschätzung der Objektverfolgung von der Referenz in x-Richtung

scheiden sich neben einer abweichenden Objektposition zusätzlich in der Schätzung der Objektlänge und -breite. Aufgrund des geringen Abstands der beiden Hypothesen zu dem zeitlich gefilterten Objekt \mathbf{x}_1 erfolgt deren Assoziation mit $\mathbf{x}_1 \Leftrightarrow \mathbf{y}_1^O$ und $\mathbf{x}_1 \Leftrightarrow \mathbf{y}_2^O$. Abbildung 7.6 veranschaulicht den Einfluss der beiden Assoziationen auf die Positionsschätzung von \mathbf{x}_1 in x-Richtung. Die Grafik zeigt die Abweichung der geschätzten Objektposition ggü. der Referenz. Auffällig sind dabei mehrfach Abweichungen, die sich in ihrem Ausmaß deutlich von der durchschnittlichen Abweichung der Entfernung unterscheiden. Das angeführte Beispiel der Übersegmentierung (siehe Abbildung 7.5b) bezieht sich auf den Aufnahmezeitpunkt bei etwa 42s. Aufgrund der zweifachen Assoziation, hervorgerufen durch Gischtbildung am Fahrzeugheck, erfolgt die Aktualisierung des Objekts \mathbf{x}_1 mit beiden Hypothesen \mathbf{y}_1^O und \mathbf{y}_2^O . Dabei verschlechtert die Integration von \mathbf{y}_2^O die Positionsschätzung von \mathbf{x}_1 , sodass sich starke Abweichungen in der Positionsschätzung ggü. der Referenz ergeben.

Abbildung 7.5d zeigt an dieser Stelle einen Vorteil der Objektverfolgung mit OLK. Im Vergleich zu Abbildung 7.5c stabilisiert die Verwendung objektlokaler Karteninformationen die Längen- und Breitenschätzung. Dadurch wirkt sich die Übersegmentierung lediglich auf die Integration der fehlerhaften Positionsschätzung und nicht auf die Objektdimension aus. Die Abbildungen 7.4 belegt das beschriebene Verhalten. Bei etwa 42s bricht die Objektlänge der Objektverfolgung ohne OLK erheblich ein. Dementgegen bleibt die Längenschätzung der Objektverfolgung mit OLK von der fehlerhaften Segmentierung un-

beeinflusst.

7.4 Lückenhafte Objekterfassung

Die fehlende Detektion einzelner Messungen \mathbf{y}_n^e der Umfeldobjekte stellt hohe Anforderungen an eine korrekte Interpretation der Messungen für die Methoden der Objektverfolgung. Aufgrund fehlerhafter Disparitätswerte der Stereokameradaten sowie durch die Teilverdeckung von Objekten ergibt sich eine lückenhafte Objekterfassung durch Sensorrohdaten. Beide Ursachen werden im Folgenden näher diskutiert.

7.4.1 Unzureichende Disparitätsberechnung

Die Objektsegmentbildung basiert auf dem Disparitätsbild der Stereokamera (vorgestellt in Kapitel 6.2.2). Unzureichende bzw. lückenhafte Berechnungen der Disparitäten führen zu einer unvollständigen Erfassung der Objekte durch Sensorrohdaten \mathbf{y}_n^e . Die Ursachen des mangelhaft erfassten Disparitätsbilds sind vielfältig (siehe Abbildung 7.7). Beispielsweise erschweren homogene Objektstrukturen die Bildpunktkorrespondenzsuche zum Erstellen der Disparitätswerte (siehe Abbildung 7.7a). Ohne die Disparität sind keine Objektsegmente für die betroffenen Bildspalten bestimmbar. Gleiches gilt für kontrastreiche Lichtverhältnisse (Abbildung 7.7b). Große Unterschiede der einzelnen Grauwerte in einem Bild bewirken eine grobe Abstufung der Helligkeitswerte pro Pixel. Dies beeinflusst die Bildpunktkorrespondenzsuche negativ und führt gleichermaßen zu einem lückenhaft ausgeprägten Disparitätsbild. Neben den Objekt- und Lichteigenschaften bestimmen ebenfalls Witterungseinflüsse die Genauigkeit der Disparitäten. Nebel oder Regen (siehe Abbildung 7.7c) reduzieren den Informationsgehalt der Bilddaten und verhindern eine erfolgreiche Bildpunktkorrespondenzsuche. Das Resultat ist erneut die partielle Repräsentation der Objekte durch einzelne Messungen \mathbf{y}_n^e .


Abbildung 7.8 veranschaulicht die Auswirkungen einer lückenhaften Objektdetektion auf die Objektverfolgung. Aufgrund kontrastreicher Lichtverhältnisse⁶ erfolgt die mangelhafte Erfassung des Objekts (siehe Abbildung 7.8a gelbes Rechteck) durch einzelne Messungen \mathbf{y}_n^e . Das Resultat sind unüberbrückbare Abstände zwischen den einzelnen Objektsegmentpositionen $\mathbf{y}_n^e(\mathbf{p})$ für eine eindeutige Segmentierung des beobachteten Objekts \mathbf{x}_1 . Dies führt zu einer Übersegmentierung von \mathbf{x}_1 (siehe Abbildung 7.8b gelbe Ellipse). Die Folge ist die Zuordnung mehrerer, auf die Aktualisierung von \mathbf{x}_1 Einfluss nehmender, Objekthypothesen⁷ \mathbf{y}_1^O und \mathbf{y}_2^O (siehe Abbildung 7.8c).

Ähnlich wie bei starkem Entfernungsräuschen der Einzelmessungen \mathbf{y}_n^e (siehe in Kapitel 7.3) liegt der Vorteil der Objektverfolgung mit ggü. ohne OLK für eine lückenhafte Objektdetektion in einer verbesserten Längen- und Breitenschätzung.


Darüber hinaus unterbinden die zeitlich konsistenten Objektdimensionen ($\mathbf{x}_1(l)$, $\mathbf{x}_1(b)$) den Objektzerfall. Über mehrere Zeitschritte betrachtet, nimmt die Schätzung $\mathbf{x}_1(b)$ aufgrund der Übersegmentierung ohne OLK stark ab. Unterschreitet $\mathbf{x}_1(b)$ einen kritischen

⁶Gegensonne


⁷Das dritte Segment ist von der Hypothesenbildung ausgeschlossen, da es die minimale Anzahl einzelner Messungen für eine Objekthypothese unterschreitet.



(a)




(b)




(c)

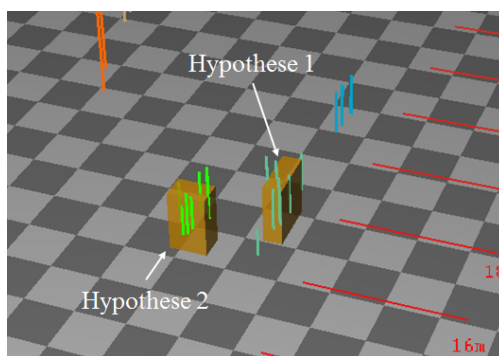
Abbildung 7.7: Lückenhafte Objekterfassung der Objektsegmente (orange) aufgrund von:
 (a) - homogener Objektstrukturen, (b) - kontrastreichen Lichtverhältnissen
 und (c) - Sichtbeeinträchtigungen durch Witterungseinflüsse (z. B.: Regentropfen im Kamerabild)




(a)



(b)



(c)



(d)

Abbildung 7.8: Einfluss fehlender Objektsegmente auf die Objektverfolgung aufgrund von Gegensonne: (a) - Referenzbild mit Visualisierung der Objektsegmente (orange) und horizontalen optischen Flussvektoren (grün), (b) - 3-D Darstellung der segmentierten Objektsegmente (Segmentzugehörigkeit ist durch verschiedene Farben gekennzeichnet), (c) - Objekthypothesenschätzung ohne OLK (in Quaderform), (d) - Objekthypothesenschätzung mit OLK (in Quaderform)

Wert, erfolgt die Assoziation von \mathbf{x}_1 nicht mehr mit beiden Objekthypothesen sondern lediglich mit \mathbf{y}_1^O . Das Resultat ist die Initialisierung eines neuen Objekts \mathbf{x}_2 aufgrund der nicht assoziierten Objekthypothese \mathbf{y}_2^O .

Die Objektverfolgung mit OLK schließt diese Art des Objektzerfalls aus, sobald die Objektkontur von \mathbf{x}_1 in K_1^O erfasst ist. Durch die Anreicherung der Objekthypothesen mit Hilfe der lokalen Karteninformation ist die Schätzung der Objektdimension unabhängig von einer fehlerhaften Erfassung der Objektgröße.

7.4.2 Teilverdeckung der Objekte

Entgegen den bereits angeführten Schwierigkeiten der Objektverfolgung mittels Stereokameradaten stellt die Teilverdeckung der Objekte ein sensor-unabhängiges Problem der Objekterfassung dar. Die Gründe der partiellen Verdeckung liegen in der eingeschränkten Sicht auf das Objekt, hervorgerufen durch andere Umfeldobjekte sowie den Grenzen des Sensorsichtbereichs. Die Auswirkungen der Teilverdeckung auf die Objektverfolgung gleichen denen der lückenhaften Objekterfassung aufgrund fehlender Disparitäten. Das Resultat aus Sicht der Sensorrohdaten \mathbf{y}_i^e ist eine unvollständige Beschreibung der Objekte. Abbildung 7.9 stellt diesen Sachverhalt grafisch dar. Abbildung 7.9a visualisiert die Teilverdeckung eines Objekts⁸ durch den fahrzeugeigenen Scheibenwischer. Abbildung 7.9b verdeutlicht den direkten Einfluss der Teilverdeckung auf die Bildung der Objekthypothese \mathbf{y}_1^O . Demnach ist das Fahrzeug durch \mathbf{y}_1^O ohne OLK nur unzureichend beschrieben. Hingegen zeigt Abbildung 7.9c eine verbesserte Objekthypothese auf Basis der OLK. Die genauere Beschreibung von \mathbf{y}_1^O durch OLK stabilisiert den Objektzustand \mathbf{x}_1 .

Abbildung 7.9d zeigt einen weiteren Fall der Teilverdeckung von Objekten. Das am rechten Bildrand befindliche Fahrzeug verlässt den Sensorsichtbereich und wird dadurch nur teilweise erfasst. Mit Hilfe der Referenzpunktschaltung (siehe Kapitel 4.7) ist die Schätzung der Objektposition sowie -dynamik in ihrer Genauigkeit unverändert. Abbildung 7.9e zeigt jedoch das Ausmaß der nur teilweise erfassten Fahrzeugkontur für die Objektverfolgung ohne OLK. Befindet sich das Fahrzeug über einen längeren Zeitraum in diesem Bereich, führt dies zu einer starken Verkleinerung der geschätzten Objektdimension. Abbildung 7.9f stellt das Ergebnis der Objektverfolgung mit OLK dar. Die Grafik verdeutlicht die signifikante Verbesserung der Zustandsschätzung des an der Sensorsichtgrenze befindlichen Objekts. Folglich liefert die Objektverfolgung mit OLK, beispielsweise für den Fall eines assistierten Spurwechsels des Sensorfahrzeugs⁹ ein deutlich genaueres Abbild des Fahrzeugumfelds.

7.5 Referenzierung der Objektkontur

Die Objektkontur der lokalen Belegungskarten ergibt sich aus der in Kapitel 6.5.5 vorgestellten Extraktion der Konturpunktmenge \mathcal{P}^K . \mathcal{P}^K stellt eine modellfreie Konturbeschreibung der Objekte dar. Diese dient einer genaueren Schätzung der Objektkontur ggü. der Beschreibung modellbasierter Formmodelle (vorgestellt in Kapitel 4.5).

⁸Fahrzeug

⁹von der linken auf die rechte Fahrspur

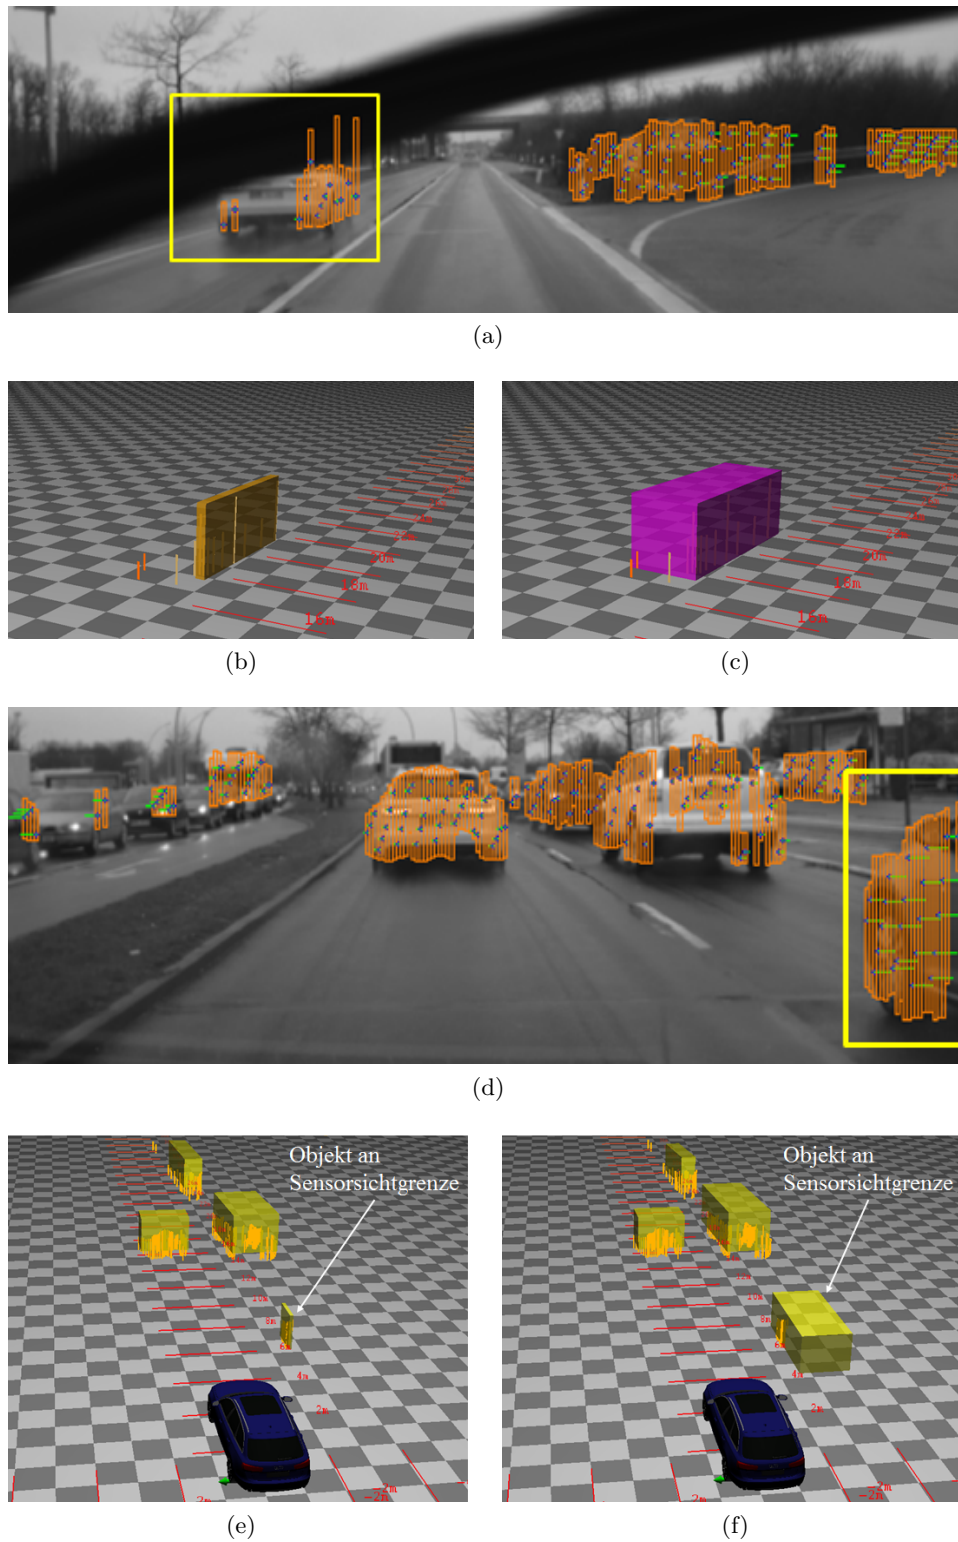


Abbildung 7.9: Einfluss der Objektverdeckung auf die Objektverfolgung: (a), (d) - Referenzbild mit Visualisierung der Objektsegmente (orange), (b) - Objekthypothese ohne OLK (in Quaderform), (c) - Objekthypothese mit OLK (in Quaderform), (e) - Objektverfolgung ohne OLK (in Quaderform), (f) - Objektverfolgung mit OLK (in Quaderform)




Abbildung 7.10: Vergleich der Objektkonturschätzung auf Basis der modellfreien 2-D Konturpunkte der Menge \mathcal{P}^K sowie dem Rechteckmodell: Die Modellierung des Rechtecks basiert auf \mathcal{P}^K .

Abbildung 7.10 vergleicht die modellfreie mit der modellbehafteten Konturschätzung für ein ausgewähltes Objekt. Dabei handelt es sich um ein, über mehrere Zeitschritte beobachtetes, Fahrzeug. Die Modellierung des Rechtecks (blau) basiert auf der modellfreien Konturbeschreibung (grün) und stellt eine Abstraktion von \mathcal{P}^K dar (vorgestellt in Kapitel 6.5.8). Um die Vergleichbarkeit der Ergebnisse beider Methoden zu gewährleisten, wird eine Seite des Rechtecks (Fahrzeugfront) von der Gegenüberstellung ausgeschlossen. Das Rechteckmodell stellt besonders im Bereich der Fahrzeugflanken eine gute Näherung des Konturverlaufs dar. Dementgegen weicht die modellbehaftete Objektkontur im Bereich des Fahrzeughecks stark von der Referenz ab. Der modellfreie Konturverlauf \mathcal{P}^K stellt für diesen Abschnitt eine deutlich genauere Schätzung dar.

Abbildung 7.11 zeigt die Abweichungen der modellfreien sowie der modellbasierten Konturschätzung von der Referenzkontur. Der betrachtete Verlauf erstreckt sich über die gesamte Beobachtungsdauer des Objekts. Zusätzlich ist die Anzahl der Konturpunkte \mathcal{P}^K über die Zeit dargestellt. In der Anfangsphase von etwa 8 s nimmt die Anzahl der Konturpunkte stark zu. Anschließend stabilisieren sich die Verläufe der modellfreien Objektkontur sowie der Rechteckkontur. Nach etwa 18 s konvergiert die Abweichung der Rechteckschätzung. Die Abweichung der modellfreien Objektkontur hingegen nähert sich mit zunehmender Anzahl an Konturpunkten weiter der Referenz an.

Die Rechteckform stellt für die Mehrzahl der Anwendungen bereits eine geeignete Beschreibung der Fahrzeugkontur dar. Ist diese jedoch möglichst exakt zu bestimmen, erweist sich




Abbildung 7.11: Abweichungen der modellfreien sowie der modellbasierten Konturschätzung gegenüber der Referenz: Zusätzlich ist die Anzahl der Konturpunkte über die Zeit dargestellt.

die modellfreie Konturbeschreibung anhand der 2-D Konturpunkte, insbesondere für den Bereich des Fahrzeughecks bzw. der Fahrzeugfront¹⁰, als vorteilhaft.

Abbildung 7.12 zeigt eine Übersicht verschiedener Objekte aus dem Fahrzeugumfeld. Auf der linken Seite ist jeweils das Referenzbild mit hervorgehobenem Objekt¹¹ abgebildet. Auf der rechten Seite ist die Kartenausprägung des hervorgehobenen Objekts dargestellt. Die Abbildung verdeutlicht die objektspezifische Charakteristik des Belegungsgitters. Der Bereich gesättigter Zellen (rot) in Abbildung 7.12a ist entsprechend der Größe eines Fußgängers sehr kompakt und gleicht in seiner geometrischen Anordnung einem Kreis bzw. einer Ellipse.

Abbildung 7.12b zeigt die lokale Belegungskarte eines Motorrads. Auffällig ist in diesem Fall die schweifartige Ausprägung von gesättigten Zellen an dem vorderen und hinteren Eckpunkt des Objekts. Aufgrund der konstanten Objektsegmentbreite im Bildbereich (siehe Abbildung 6.2) unterliegt die Entfernungsschätzung der Objektsegmente des linken und rechten Objektrands über die Zeit starken Schwankungen. Diese resultieren aus großen Disparitätsunterschieden der einzelnen Objektsegmente von einem Zeitschritt zum nächsten. Die Ursache für diese Differenz ist die wechselnde Häufigkeit von Hintergrunddisparitäten der Objektsegmente an den Objekträndern. Objektstrukturen, die vertikal

¹⁰Gegenverkehr

¹¹gelbes Rechteck

keine geschlossene Kontur (z. B.: ein Motorrad) besitzen, begünstigen zusätzlich das Entfernungsrauschen der einzelnen Objektsegmente. Ebenso wie an den Objektrandbereichen basiert die Entfernung dieser Objektsegmente auf Disparitäten des Objekts und des Hintergrunds.

Die Abbildungen 7.12c und 7.12d weisen eine typische, durch die Beobachtung der Fahrzeugflanke sowie dem Fahrzeugheck hervorgerufene, L-Form-Charakteristik auf. Auffällig ist hierbei ein geschlossener Konturverlauf der linken Flanke des Transporters (d) ggü. der Flanke des Kleinwagens (c). Die Grafiken und Schriftzüge auf dem Transporter begünstigen die Suche von Bildpunktkorrespondenzen für die Berechnung der Objektsegmente. Dementsprechend ergibt sich für dieses Beispiel eine lückenlose Objekterfassung. Neben der geschlossenen Objektkontur resultiert die texturreiche Objektbeschaffenheit in qualitativ hochwertigen Objektsegmentpositionen $\mathbf{y}_n^e(\mathbf{p})$. Diese zeichnen sich besonders durch ein geringes Entfernungsrauschen aus. Demgegenüber unterliegt die Bildung der Objektsegmente für den Kleinwagen weiterhin dem Problem der lückenhaften Objekterfassung aufgrund unzureichender Disparitäten (vorgestellt in Kapitel 7.4.1).

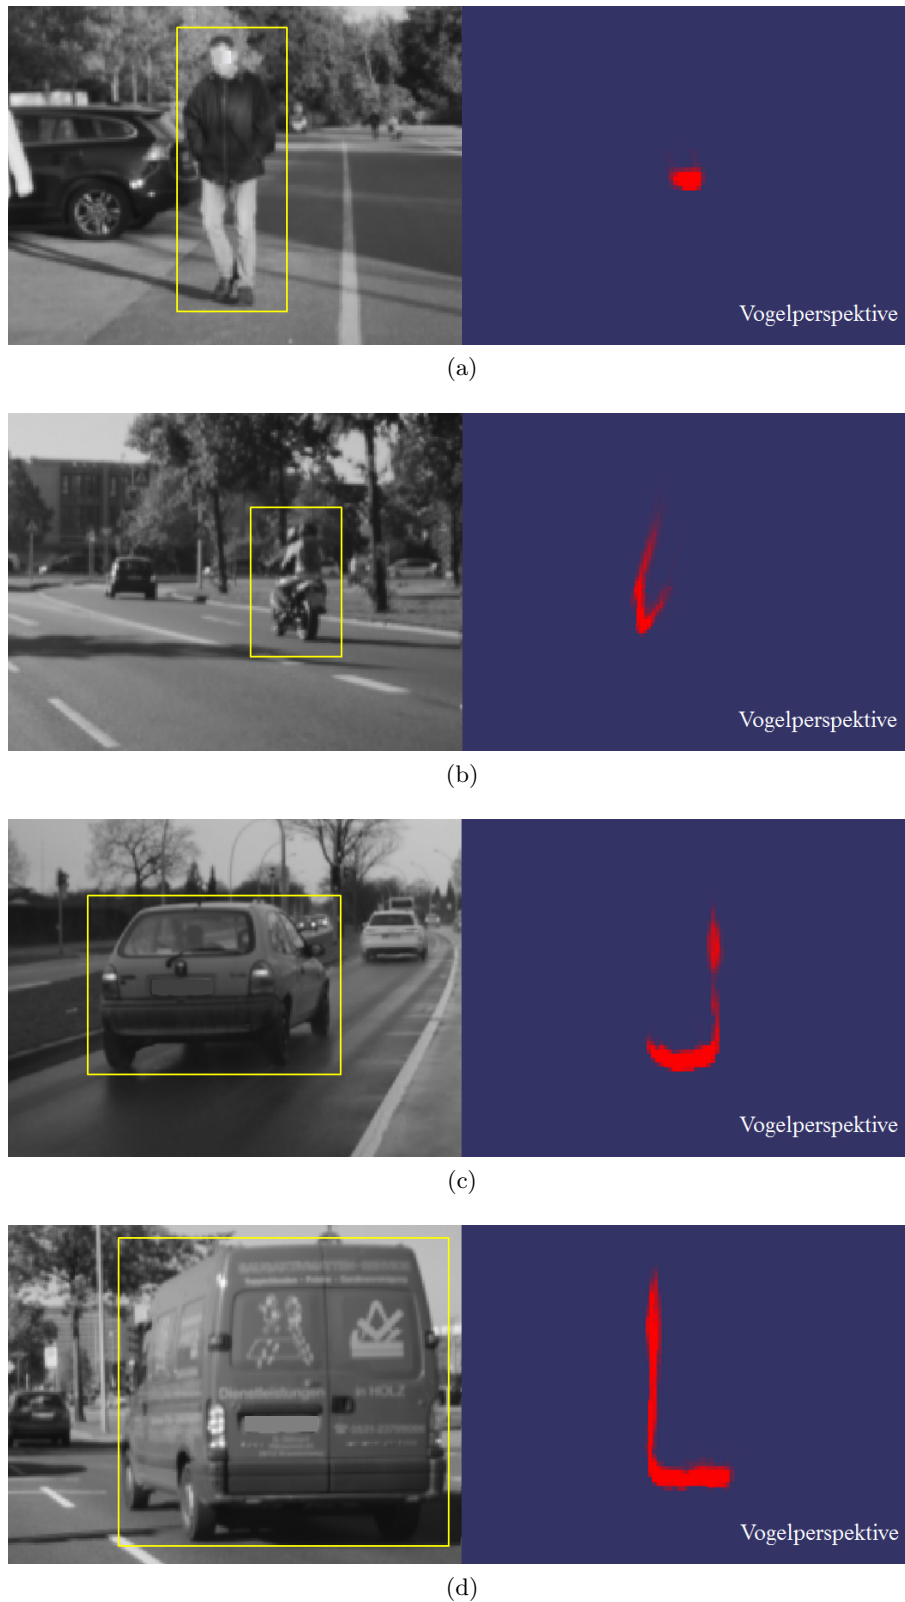


Abbildung 7.12: Zusammenstellung verschiedener Objekte aus dem Fahrzeugumfeld: Links ist das Referenzbild mit hervorgehobenem Objekt (gelbes Rechteck) dargestellt. Rechts befindet sich die entsprechende Ausprägung der OLK: (a) - Fußgänger, (b) - Motorrad, (c) - Kleinwagen, (d) - Transporter

Kapitel 8

Schlussbetrachtung

Die Schlussbetrachtung fasst die erarbeiteten Ergebnisse dieser Dissertation zusammen. Darüber hinaus werden weiterführende Arbeiten bezüglich der Nutzung von OLK zur Verbesserung der Umfeldwahrnehmung von ADAS diskutiert.

8.1 Zusammenfassung

Die Erfassung und Interpretation des Fahrzeugumfelds für teil- und hochautomatisiertes Fahren verfolgt das Ziel, ein umfassendes Verständnis über andere Verkehrsteilnehmer anhand von Sensordaten zu schaffen. Die gegenwärtige Umfeldmodellierung mit automotivetauglichen Sensoren bietet hierbei lediglich von der menschlichen Wahrnehmung stark abstrahierte und für ADAS teilweise ungeeignete Modelle der Objektbeschreibung an. Demnach stellt die Verbesserung der Umfeldmodellierung für fahrzeugtaugliche Sensoren eine Voraussetzung für die Realisierung hochautomatisierter Fahrfunktionen durch ADAS dar.

Aktuelle Methoden der modellbehafteten sowie der modellfreien Wahrnehmung des Fahrzeugumfelds (siehe Kapitel 4 und 5) weisen weitestgehend komplementäre Vorteile auf. Dementsprechend bietet die Kopplung beider Ansätze Verbesserungspotential hinsichtlich der Beschreibung des Fahrzeugumfelds.

Das entwickelte Konzept der Kombination modellbasierter mit modellfreien Methoden der Umfeldwahrnehmung (siehe Kapitel 6) leistet einen Beitrag zur Verbesserung der Objektverfolgung. Dessen Implementierung sowie Validierung erfolgte anhand von Sensordaten eines fahrzeugtauglichen Stereokamerasystems.

Die modellbasierte Objektverfolgung umfasst die Formulierung von Objekthypothesen \mathbf{y}_l^O auf Basis der Stereokameradaten \mathbf{y}_n^g sowie die zeitliche Stabilisierung der Objekte mittels Methoden der Kalman-Filterung. Neben der Schätzung der Objektzustände \mathbf{x}_i erfolgt die detaillierte Beschreibung der Objektkontur durch OLK (siehe Kapitel 6.5). Sensordaten \mathbf{y}_n^g , die zur Aktualisierung des Objekts in der modellbasierten Objektverfolgung führen, sind hierbei in die objektspezifische Belegungskarte zu integrieren. Das Ergebnis stellt einen erhöhten Informationsgehalt der Konturbeschreibung der Objekte ggü. einfachen geometrischen Formmodellen dar. Die Evaluierung der Objektverfolgung mit OLK (siehe Kapitel 7) belegt ein vorteilhaftes Verhalten dieses Konzepts anhand:

- der Verbesserung der modellbasierten Zustandsschätzung \mathbf{x}_i mittels Integration zusätzlicher Objektinformationen aus OLK.

- der Stabilisierung der Objektkontur.
- einer geringeren Auswirkung von starkem Entfernungsruschen der Sensordaten $\mathbf{y}_n^e(\mathbf{p})$ auf die modellbasierte Zustandsschätzung \mathbf{x}_i .
- der Kompensation der Auswirkungen einer lückenhaften Erfassung der Objekte bedingt durch eingeschränkte Sensormessungen.
- einer zeitlich konsistenten und modellfreien Konturbeschreibung der Objekte.

Die qualitative sowie quantitative Bewertung der Objektverfolgung mit OLK verdeutlicht die robuste Detektion und Beschreibung von Objekten unter Einhaltung der Echtzeitanforderung. Für Applikationen, wie beispielsweise dem automatischen Ausweichen, bedeutet dies einen Mehrwert für die Funktionsauslegung. Durch die präzise und mit kleineren Unsicherheiten behaftete Objektbeschreibung lässt sich z. B. eine eng am dem Objekt vorbeiführend Trajektorie zur Kollisionsvermeidung berechnen. Aufgrund der präzisen Trajektorie ist der Auslösezeitpunkt des Fahrmanövers genauer bestimmbar.

8.2 Ausblick

Der Ausblick zeigt potentielle Anknüpfungspunkte für die Verbesserung der Objektverfolgung mittels objektlokaler Belegungskarten auf.

Verbesserung der Segmentierung von Rohdaten Die lückenhafte Erfassung der Objekte mit Sensorrohdaten (siehe Kapitel 7.4) führt häufig zu einer Übersegmentierung der Objekte und resultiert in fehlerhaft formulierten Objekthypothesen. Diese Hypothesen verfälschen die Schätzung einzelner Objektzustände und tragen zu einer Verschlechterung der Objektverfolgung bei. Im Gegensatz dazu führen zu geringe Abstände zwischen den Messungen verschiedener Objekte zu einer Untersegmentierung der beobachteten Szene. Das Resultat ist das Versagen der Trennfähigkeit einzelner Objekte durch die modellbasierte Objektverfolgung.

Abbildung 8.1 zeigt jeweils ein Beispiel für die Über- sowie Untersegmentierung anhand von Stereokameradaten. Die Segmentierung basiert auf dem aktuellen Messzyklus des Sensors ohne Berücksichtigung vorangegangener Messungen \mathbf{y}_n^e . Es ergeben sich Segmentierungsfehler, wenn der Abstand zwischen einzelnen Messungen eines Objekts zu groß bzw. der Abstand einzelner Messungen zwischen zwei Objekten zu gering ist.

Durch das Einbeziehen der lokal akkumulierten Karteninformationen lässt sich das fehlerhafte Ergebnis der Rohdatensegmentierung korrigieren. Am Beispiel der Abbildung 8.1a bedeutet dies die Zusammenführung der beiden Segmente, die sich auf der Kontur des Objekts (rote Zellen der Belegungskarte) befinden. Der entgegengesetzte Fall ist in Abbildung 8.1b dargestellt. Die lokale Belegungskarte beinhaltet eine über die Zeit nicht geschlossene Objektkontur. Entsprechend der beiden Konturen kann die Trennung des Segments (grün) in zwei Segmente erfolgen. Demnach lässt sich das Ergebnis der Segmentierung durch die Anwendung objektlokaler Belegungskarten verbessern.

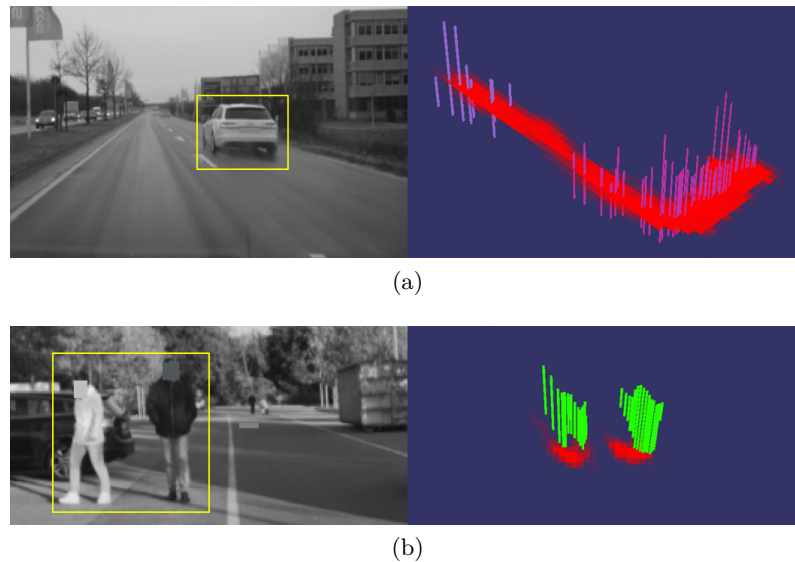


Abbildung 8.1: Verbesserungspotential hinsichtlich der Segmentierungsergebnisse durch objektlokale Belegungskarten (links - Referenzbild mit hervorgehobenem Objekt, rechts - objektlokale Belegungskarte des Objekts mit segmentierten Messungen dargestellt durch verschiedene Farben): (a) - übersegmentiertes Objekt aufgrund unüberbrückbarer Abstände zwischen einzelnen Messungen (3-D Perspektive), (b) - Untersegmentierung aufgrund zu geringer Abstände zwischen den Messungen beider Objekte (3-D Perspektive)

Objektklassifizierung Abbildung 7.12 veranschaulicht die unterschiedlich ausgeprägten Objektkonturen verschiedener Verkehrsteilnehmer. Hierbei lassen sich die in OLK enthaltenen Konturinformationen für eine Klassifizierung der Objekte nutzen. Weiterhin ist für OLK mit Höheninformation (siehe Abbildung 6.20) die Analyse des Höhenprofils für eine Einteilung der Objekte in verschiedene Klassen¹ denkbar.

Die ermittelte Objektklasse der jeweiligen OLK ist auf die Objekthypothesen zu übertragen. Dadurch lässt sich beispielsweise ein geeignetes Bewegungsmodell zur Schätzung der Objektzustände in der modellbasierten Objektverfolgung bestimmen. Die Folge ist eine präzisere Modellbeschreibung für die zeitliche Filterung des Objekts.

Austausch von Karteninformationen Die Mehrzahl der in Kapitel 3.2 vorgestellten Ansätze der Umfeldkartierung und Objektverfolgung basiert auf der Unterscheidung von stationären sowie bewegten Objekten. Für diesen Zweck erfolgt die Modellierung statischer Hindernisse in einer Belegungskarte. In Kombination mit OLK können die statische Hinderniskarte und die lokalen Belegungskarten mittels Austausch von Zellinformationen voneinander profitieren.

Sind beispielsweise die Konturinformation eines parkenden Fahrzeugs in der Hinderniskarte enthalten, kann die Zellinformation dieses Objekts aus der Hinderniskarte direkt in OLK übertragen werden, sobald sich das Fahrzeug in Bewegung setzt. Auf diese Weise lässt sich das Einschwingverhalten für das Ausprägen der Objektkontur zeitlich minimieren. Die

¹z. B.: Fußgänger, Motorrad, Personkraftwagen, Transporter oder Lastkraftwagen

Folge ist eine schnellere Anreicherung der Objekthypothesen \mathbf{y}_l^O mit lokalen Karteninformationen zur verbesserten Schätzung der Objektzustände \mathbf{x}_i .

Geht andererseits ein Fahrzeug aus dem bewegten in einen geparkten Zustand über, übernimmt die Hinderniskarte die Belegungsinformationen der OLK.


Anwendung mit Laserscannerdaten Die Validierung des vorgestellten Konzepts, der Objektverfolgung mit OLK, erfolgte anhand von Daten eines fahrzeugtauglichen Stereokamerasystems. Dabei unterliegen die Messungen \mathbf{y}_n^o teilweise starken Schwankungen in der Entfernungsbestimmung. Dieses Rauschen bildet sich durch große Bereiche gesättigter Zellen in OLK ab und verschlechtert somit den Informationsgehalt der Belegungskarte. Dem geschuldet lässt sich beispielsweise für die Positionsschätzung der Objekthypothesen $\mathbf{y}_l^O(\mathbf{p})$ keine Verbesserung durch den Einsatz von OLK erzielen.

In Kombination mit einem fahrzeugtauglichen Laserscanner verspricht die Anwendung der OLK eine weiterführende Verbesserung der Objektverfolgung aufgrund des erheblich reduzierten Entfernungsrauschens ggü. Stereokameradaten. Abbildung 8.2 stellt die unterschiedliche Positionsgenauigkeit der Stereokamera- sowie Laserscannerdaten qualitativ dar. Hierbei lassen sich die einzelnen Messungen der Stereokamera sowie des Laserscanners für ein detektiertes Fahrzeugheck (siehe Abbildung 8.2a gelbes Rechteck) miteinander vergleichen. Im Besonderen verdeutlicht Abbildung 8.2c die starken Unterschiede der Positionsgenauigkeit zwischen Stereokamera- und Laserscannerdaten.


Der Einsatz von OLK zeigt über die vorliegende Arbeit hinaus enormes Potential zur Verbesserung der Umfeldwahrnehmung.



(a)



(b)



(c)

Abbildung 8.2: Qualitativer Vergleich der Positionsgenauigkeit von Stereokamera- und Laserscannerdaten: (a) - Referenzbild mit Visualisierung der Objektsegmente, (b) - 3-D Darstellung der Objektsegmente (orange) und Laserscannerdaten (weiß) aus Sicht oberhalb der Sensoren (3-D Perspektive), (c) - 3-D Darstellung der Objektsegmente (orange) und Laserscannerdaten (weiß) von links oben auf das Objekt blickend (3-D Perspektive)

Literaturverzeichnis

- [ADAC 2013] ADAC: *Fahrerassistenzsysteme: Was tun die Assistenten - und wie gut unterstützen sie den Fahrer?* 2013. – URL <http://www.adac.de/infotestrat/technik-und-zubehoer/fahrerassistenzsysteme/>. – Zugriffsdatum: 22.11.2013
- [Ankerst u. a. 1999] ANKERST, M. ; BREUNIG, M.M. ; KRIEGEL, H.P. ; SANDER, J.: OPTICS: ordering points to identify the clustering structure. In: *ACM SIGMOD Record* 28 (1999), Nr. 2, S. 49–60
- [ARTRAC 2013] ARTRAC: *ARTRAC - Advanced Radar Tracking and Classification for Enhanced Road Safety*. 2013. – URL <http://artrac.org/index.php/page/ARTRAC-2011-01-10>. – Zugriffsdatum: 07.06.2013
- [Aue u. a. 2011] AUE, J. ; LANGER, D. ; MULLER-BESSLER, B. ; HUHNKE, B.: Efficient segmentation of 3D LIDAR point clouds handling partial occlusion. In: *Intelligent Vehicles Symposium (IV)* IEEE (Veranst.), 2011, S. 423–428
- [Aue u. a. 2013a] AUE, J. ; SCHMID, M. R. ; GRAF, T. ; EFFERTZ, J.: Improved Object Tracking from Detailed Shape Estimation Using Object Local Grid Maps with Stereo. In: *International Conference on Intelligent Transportation Systems (ITSC)* IEEE (Veranst.), 2013
- [Aue u. a. 2013b] AUE, J. ; SCHMID, M. R. ; GRAF, T. ; EFFERTZ, J. ; MUEHLFELLNER, P.: Object Tracking from Medium Level Stereo Camera Data Providing Detailed Shape Estimation Using Local Grid Maps. In: *Intelligent Vehicles Symposium (IV)* IEEE (Veranst.), 2013
- [Badino u. a. 2007] BADINO, Hernán ; FRANKE, Uwe ; MESTER, Rudolf: Free space computation using stochastic occupancy grids and dynamic programming. In: *Workshop on Dynamical Vision, ICCV, Rio de Janeiro, Brazil* Bd. 20, 2007
- [Badino u. a. 2009] BADINO, Hernan ; FRANKE, Uwe ; PFEIFFER, David: The Stixel World - A Compact Medium Level Representation of the 3D-World. In: *Proceedings of the 31st DAGM Symposium on Pattern Recognition*. Jena and Germany : Springer-Verlag, Berlin, Heidelberg, 2009, S. 51–60. – ISBN 978-3-642-03797-9
- [Bar-Shalom und Li 1987] BAR-SHALOM, Y. ; LI, X.R.: *Tracking and data association*. Academic Press Professional, Inc., 1987
- [Bar-Shalom und Li 1993] BAR-SHALOM, Y. ; LI, X.R.: Estimation and tracking- Principles, techniques, and software. In: *Norwood, MA: Artech House, Inc, 1993*. (1993)
- [Bar-Shalom und Li 1995] BAR-SHALOM, Y. ; LI, X.R.: Multitarget-Multisensor Tracking: Principles and Techniques. YBS, 1995. – Forschungsbericht

- [Bergman 1999] BERGMAN, N.: Recursive Bayesian Estimation. In: *Department of Electrical Engineering, Linköping University, Linköping Studies in Science and Technology. Doctoral dissertation* (1999), Nr. 579
- [Bishop und Nasrabadi 2006] BISHOP, Christopher M. ; NASRABADI, Nasser M.: *Pattern recognition and machine learning*. Bd. 1. springer New York, 2006
- [Bishop 2000] BISHOP, Richard: A survey of intelligent vehicle applications worldwide. In: *Intelligent Vehicles Symposium (IV)*, 2000, S. 25–30
- [BLACKMAN und POPOLI 1999] BLACKMAN, Samuel ; POPOLI, Robert: Design and analysis of modern tracking systems. (1999)
- [Bouzouraa und Hofmann 2011] BOUZOURAA, M. E. ; HOFMANN, U.: Fusion kartenbasierter Umfeldwahrnehmung mit modellbasierter Objektverfolgung für Fahrerassistenzsysteme. In: *Workshop Fahrerassistenzsysteme*. Walting and Deutschland, 2011, S. 115—123
- [Bouzouraa 2012] BOUZOURAA, Mohamed E.: *Belegungskartenbasierte Umfeldwahrnehmung in Kombination mit objektbasierten Ansätzen für Fahrerassistenzsysteme*. München, Technische Universität München, Dissertation, 2012
- [Bouzouraa und Hofmann 2010] BOUZOURAA, Mohamed E. ; HOFMANN, Ulrich: Fusion of occupancy grid mapping and model based object tracking for driver assistance systems using laser and radar sensors. In: *Intelligent Vehicles Symposium (IV) IEEE* (Veranst.), 2010, S. 294–300
- [Brechtel u. a. 2010] BRECHTEL, S. ; GINDELE, T. ; DILLMANN, R.: Recursive importance sampling for efficient grid-based occupancy filtering in dynamic environments. In: *International Conference on Robotics and Automation, (ICRA) IEEE* (Veranst.), 2010, S. 3932–3938
- [Buntine 1994] BUNTINE, Wray L.: Operations for learning with graphical models. In: *arXiv preprint cs/9412102* (1994)
- [Chen und Medioni 1991] CHEN, Yang ; MEDIONI, Gérard: Object modeling by registration of multiple range images. In: *International Conference on Robotics and Automation, (ICRA) IEEE* (Veranst.), 1991, S. 2724–2729
- [Cielniak u. a. 2010] CIELNIAK, Grzegorz ; DUCKETT, Tom ; LILIENTHAL, Achim J.: Data association and occlusion handling for vision-based people tracking by mobile robots. In: *Robotics and Autonomous Systems* 58 (2010), Nr. 5, S. 435–443
- [Davey u. a. 2007] DAVEY, Samuel J. ; RUTTEN, Mark G. ; CHEUNG, Brian u. a.: A comparison of detection performance for several track-before-detect algorithms. In: *EURASIP Journal on Advances in Signal Processing* 2008 (2007)
- [Doucet und Johansen 2009] DOUCET, A. ; JOHANSEN, A.M.: A tutorial on particle filtering and smoothing: fifteen years later. In: *Handbook of Nonlinear Filtering* (2009), S. 656–704

- [Doucet u. a. 2000] DOUCET, Arnaud ; GODSILL, Simon ; ANDRIEU, Christophe: On sequential Monte Carlo sampling methods for Bayesian filtering. In: *Statistics and computing* 10 (2000), Nr. 3, S. 197–208
- [Douillard u. a. 2009] DOUILLARD, Bertrand ; BROOKS, Alex ; RAMOS, Fabio: A 3D laser and vision based classifier. In: *Intelligent Sensors, Sensor Networks and Information Processing (ISSNIP), 2009 5th International Conference on* IEEE (Veranst.), 2009, S. 295–300
- [Dyckmanns u. a. 2011] DYCKMANNS, Helgo ; MATTHAEI, Richard ; MAURER, Markus ; LICHT, Bernd: Object tracking in urban intersections: Active interacting multi model filter with handling of uncertainties of map matching. In: *International Conference on Information Fusion (FUSION)* IEEE (Veranst.), 2011, S. 1–8
- [Effertz 2008] EFFERTZ, J.: Sensor architecture and data fusion for robotic perception in urban environments at the 2007 DARPA urban challenge. In: *Robot Vision* (2008), S. 275–290
- [Effertz 2009] EFFERTZ, Jan: *Autonome Fahrzeugführung in urbaner Umgebung durch Kombination objekt- und kartenbasierter Umfeldmodelle*, Dissertation, 2009
- [Elfes 1989] ELFES, A.: Using occupancy grids for mobile robot perception and navigation. In: *Computer* 22 (1989), Nr. 6, S. 46–57. – ISSN 0018-9162
- [Erbs u. a. 2011] ERBS, Friedrich ; BARTH, Alexander ; FRANKE, Uwe: Moving vehicle detection by optimal segmentation of the dynamic Stixel World. In: *Intelligent Vehicles Symposium (IV)* IEEE (Veranst.), 2011, S. 951–956
- [Eskandarian 2012] ESKANDARIAN, Azim: *Handbook of intelligent vehicles*. Springer, 2012
- [Ess u. a. 2010] ESS, Andreas ; SCHINDLER, Konrad ; LEIBE, Bastian ; VAN GOOL, Luc: Object detection and tracking for autonomous navigation in dynamic environments. In: *The International Journal of Robotics Research* 29 (2010), Nr. 14, S. 1707–1725
- [Ester u. a. 1996] ESTER, M. ; KRIEGEL, H.P. ; SANDER, J. ; XU, X.: A density-based algorithm for discovering clusters in large spatial databases with noise. In: *Proceedings of the 2nd International Conference on Knowledge Discovery and Data mining* Bd. 1996 AAAI Press (Veranst.), 1996, S. 226–231
- [Forwiss 2013] FORWISS: *PRéVENT: Aktive präventive Fahrsicherheitsanwendungen*. 2013. – URL <http://www.forwiss.uni-passau.de/de/projectsingle/52/main.html>. – Zugriffsdatum: 15.05.2013
- [Geduld 2012] GEDULD, Georg: Lidarsensorik. In: *Handbuch Fahrerassistenzsysteme*. Springer, 2012, S. 172–186
- [Hancock u. a. 1999] HANCOCK, J.A. u. a.: Laser intensity-based obstacle detection and tracking / Carnegie Mellon University. 1999. – Forschungsbericht
- [Hartley und Zisserman 2000] HARTLEY, R. ; ZISSERMAN, A.: *Multiple view geometry in computer vision*. Bd. 2. Cambridge Univ Press, 2000

- [Hartley und Zisserman 2003] HARTLEY, Richard ; ZISSERMAN, Andrew: *Multiple view geometry in computer vision*. 2. Cambridge and UK and New York : Cambridge University Press, 2003. – ISBN 9780521540513
- [Hastings 1970] HASTINGS, W K.: Monte Carlo sampling methods using Markov chains and their applications. In: *Biometrika* 57 (1970), Nr. 1, S. 97–109
- [Himmelsbach u. a. 2008] HIMMELSBACH, Michael ; MÜLLER, Andre ; LÜTTEL, Thorsten ; WÜNSCHE, Hans-Joachim: Lidar-based 3d object perception. In: *Proceedings of 1st International Workshop on Cognition for Technical Systems*, 2008
- [Hipp 2012] HIPPE, Dipl.-Ing. E.: *Das Verbundprojekt UR:BAN und seine Vorgängerprojekte*. 2012. – URL <http://www.tuvpt.de/fileadmin/downloads/HZP/HIPP.pdf>. – Zugriffsdatum: 07.05.2013
- [Hoover u. a. 1996] HOOVER, Adam ; JEAN-BAPTISTE, Gillian ; JIANG, Xiaoyi ; FLYNN, Patrick J. ; BUNKE, Horst ; GOLDBERG, Dmitry B. ; BOWYER, Kevin ; EGGERT, David W. ; FITZGIBBON, Andrew ; FISHER, Robert B.: An experimental comparison of range image segmentation algorithms. In: *Pattern Analysis and Machine Intelligence, IEEE Transactions on* 18 (1996), Nr. 7, S. 673–689
- [interactIVe 2013] INTERACTIVE: *interactIVe - Accident avoidance by active intervention for Intelligent Vehicle*. 2013. – URL <http://www.interactive-ip.eu/>. – Zugriffsdatum: 06.05.2013
- [Jähne 2005] JÄHNE, B.: *Digitale Bildverarbeitung*. Springer, 2005
- [Kalman u. a. 1960] KALMAN, R.E. u. a.: A new approach to linear filtering and prediction problems. In: *Journal of basic Engineering* 82 (1960), Nr. 1, S. 35–45
- [Kammel u. a. 2008] KAMMEL, Sören ; ZIEGLER, Julius ; PITZER, Benjamin ; WERLING, Moritz ; GINDELE, Tobias ; JAGZENT, Daniel ; SCHRÖDER, Joachim ; THUY, Michael ; GOEBL, Matthias ; HUNDELSHAUSEN, Felix v. u. a.: Team AnnieWAY’s autonomous system for the 2007 DARPA Urban Challenge. In: *Journal of Field Robotics* 25 (2008), Nr. 9, S. 615–639
- [Ko-FAS 2013] KO-FAS, Forschungsinitiative: *Forschungsinitiative Ko-FAS - Kooperative Sensorik und kooperative Perzeption für die Präventive Sicherheit im Straßenverkehr*. 2013. – URL <http://ko-fas.de/>. – Zugriffsdatum: 06.05.2013
- [Konstantinova u. a. 2003] KONSTANTINOVA, Pavlina ; UDVAREV, Alexander ; SEMERDJIEV, Tzvetan: A study of a target tracking algorithm using global nearest neighbor approach. In: *Proc. of Computer Systems and Technologies* (2003), S. 290–295
- [Lategahn u. a. 2010] LATEGAHN, Henning ; DERENDARZ, Wojciech ; GRAF, Thorsten ; KITZ, Bernd ; EFFERTZ, Jan: Occupancy grid computation from dense stereo and sparse structure and motion points for automotive applications. In: *Intelligent Vehicles Symposium (IV) IEEE* (Veranst.), 2010, S. 819–824
- [Lee u. a. 2003] LEE, Lily ; DALLEY, Gerald ; TIEU, Kinh: Learning pedestrian models for silhouette refinement. In: *European Conference on Computer Vision (ECCV) IEEE* (Veranst.), 2003, S. 663–670

- [Li und Jilkov 2003] LI, X. R. ; JILKOV, Vesselin P.: Survey of maneuvering target tracking. Part I. Dynamic models. In: *Aerospace and Electronic Systems, IEEE Transactions on* 39 (2003), Nr. 4, S. 1333–1364
- [Lindl 2009] LINDL, Rudi: *Tracking von Verkehrsteilnehmern im Kontext von Multisensorsystemen*, München, Techn. Univ., Diss., 2009, Dissertation, 2009
- [Lloyd 1982] LLOYD, S.: Least squares quantization in PCM. In: *Information Theory, IEEE Transactions on* 28 (1982), Nr. 2, S. 129–137
- [Matzka und Altendorfer 2009] MATZKA, Stephan ; ALTENDORFER, Richard: A comparison of track-to-track fusion algorithms for automotive sensor fusion. In: *Multisensor Fusion and Integration for Intelligent Systems*. Springer, 2009, S. 69–81
- [Mendes u. a. 2004] MENDES, Abel ; BENTO, Luis C. ; NUNES, Urbano: Multi-target detection and tracking with a laser scanner. In: *Intelligent Vehicles Symposium (IV) IEEE* (Veranst.), 2004, S. 796–801
- [Möller u. a. 2005] MÖLLER, T. ; KRAFT, H. ; FREY, J. ; ALBRECHT, M. ; LANGE, R.: Robust 3d measurement with pmd sensors. In: *Range Imaging Day, Zürich* (2005)
- [Montemerlo u. a. 2008] MONTEMERLO, Michael ; BECKER, Jan ; BHAT, Suhrid ; DAHLKAMP, Hendrik ; DOLGOV, Dmitri ; ETTINGER, Scott ; HAEHNEL, Dirk ; HILDEN, Tim ; HOFFMANN, Gabe ; HUHNKE, Burkhard u. a.: Junior: The stanford entry in the urban challenge. In: *Journal of Field Robotics* 25 (2008), Nr. 9, S. 569–597
- [Moosmann 2013] MOOSMANN, Frank: *Interlacing Self-Localization, Moving Object Tracking and Mapping for 3D Range Sensors*, Dissertation, 2013. – URL <http://digbib.ubka.uni-karlsruhe.de/volltexte/1000032359>
- [Moosmann und Fraichard 2010] MOOSMANN, Frank ; FRAICHARD, Thierry: Motion estimation from range images in dynamic outdoor scenes. In: *International Conference on Robotics and Automation, (ICRA) IEEE* (Veranst.), 2010, S. 142–147
- [Moras u. a. 2011] MORAS, Julien ; CHERFAOUI, Veronique ; BONNIFAIT, Philippe: Moving Objects Detection by Conflict Analysis in Evidential Grids. In: *Intelligent Vehicles Symposium (IV)*. Baden-Baden and Germany, 2011, S. 1120–1125
- [Munz 2011] MUNZ, M.: *Generisches Sensorfusionsframework zur gleichzeitigen Zustands- und Existenzschätzung für die Fahrzeugumfeldererkennung*, PhD Thesis, Universität Ulm, Institut für Mess-, Regel- und Mikrotechnik, Dissertation, 2011
- [Murphy 2002] MURPHY, K.P.: *Dynamic bayesian networks: representation, inference and learning*, University of California, Dissertation, 2002
- [Nguyen 2012] NGUYEN, Thien N.: *Objekt- und kartenbasierte Beschreibung der Umgebung ausgehend von einer stereokamerabasierten Umfelderkennung*, Dissertation, 2012
- [Petrovskaya und Thrun 2009] PETROVSKAYA, Anna ; THRUN, Sebastian: Model based vehicle detection and tracking for autonomous urban driving. In: *Journal of Autonomous Robots* 26 (2009), Nr. 2-3, S. 123–139

- [Pfeiffer und Franke 2010] PFEIFFER, David ; FRANKE, Uwe: Efficient representation of traffic scenes by means of dynamic Stixels. In: *Intelligent Vehicles Symposium (IV)* IEEE (Veranst.), 2010, S. 217–224
- [Rauskolb u. a. 2008] RAUSKOLB, Fred W. ; BERGER, Kai ; LIPSKI, Christian ; MAGNOR, Marcus ; CORNELSEN, Karsten ; EFFERTZ, Jan ; FORM, Thomas ; GRAEFE, Fabian ; OHL, Sebastian ; SCHUMACHER, Walter u. a.: Caroline: An autonomously driving vehicle for urban environments. In: *Journal of Field Robotics* 25 (2008), Nr. 9, S. 674–724
- [Reif 2010] REIF, Konrad: *Sensoren im Kraftfahrzeug*. Springer, 2010
- [Scheck 2003] SCHECK, Florian: *Theoretische Physik 1: Mechanik. Von den Newtonschen Gesetzen zum deterministischen Chaos*. Bd. 1. Springer DE, 2003
- [Schindler 2007] SCHINDLER, Erich: *Fahrdynamik: Grundlagen des Lenkverhaltens und ihre Anwendung für Fahrzeugregelsysteme*. Bd. 685. expert verlag, 2007
- [Schmid 2012] SCHMID, Matthias R.: *Umgebungserfassung für Fahrerassistenzsysteme mit hierarchischen Belegungskarten*. Neubiberg, Universität der Bundeswehr München, Fakultät für Luft- und Raumfahrttechnik, Dissertation, 2012. – URL <http://athene.bibl.unibw-muenchen.de:8081/download/90500/90500.pdf>
- [Schubert u. a. 2011] SCHUBERT, Robin ; ADAM, Christian ; OBST, Marcus ; MATTERN, Norman ; LEONHARDT, Veit ; WANIELIK, Gerd: Empirical evaluation of vehicular models for ego motion estimation. In: *Intelligent Vehicles Symposium (IV)* IEEE (Veranst.), 2011, S. 534–539
- [Schubert u. a. 2012] SCHUBERT, Robin ; ADAM, Christian ; RICHTER, Eric ; BAUER, Sven ; LIETZ, Holger ; WANIELIK, Gerd: Generalized probabilistic data association for vehicle tracking under clutter. In: *Intelligent Vehicles Symposium (IV)* IEEE (Veranst.), 2012, S. 962–968
- [Schueler u. a. 2012] SCHUELER, K. ; WEIHERER, T. ; BOUZOURAA, E. ; HOFMANN, U.: 360 Degree multi sensor fusion for static and dynamic obstacles. In: *Intelligent Vehicles Symposium (IV)* IEEE (Veranst.), 2012, S. 692–697
- [Schulz u. a. 2003] SCHULZ, Dirk ; BURGARD, Wolfram ; FOX, Dieter ; CREMERS, Armin B.: People tracking with mobile robots using sample-based joint probabilistic data association filters. In: *International Journal of Robotics Research* 22 (2003), Nr. 2, S. 99–116
- [Shafer 1976] SHAFER, Glenn: *A mathematical theory of evidence*. Bd. 1. Princeton University Press, 1976
- [simTD 2013] SIMTD: *simTD: Mit Car-to-X-Kommunikation die Zukunft der Verkehrssicherheit und Mobilität gestalten*. 2013. – URL <http://www.simtd.org>. – Zugriffsdatum: 06.05.2013
- [Skutek 2006] SKUTEK, Michael: *Ein PreCrash-System auf Basis multisensorieller Umgebungserfassung*. Shaker, 2006

- [Steinemann u. a. 2012] STEINEMANN, P. ; KLAPPSTEIN, J. ; DICKMANN, J. ; HUNDELSHAUSEN, F. von ; WÜNSCHE, H.J.: Geometric-Model-Free Tracking of Extended Targets Using 3D-LIDAR-Measurements. In: *Proc. of SPIE Vol Bd. 8379*, 2012, S. 83790C–1
- [Streller und Dietmayer 2002] STRELLER, D. ; DIETMAYER, K.: Lidar-Sensoren zur Umfelderkennung bei Straßenfahrzeugen. In: *Messtechnisches Symposium des AHMT eV Bd. 16*, 2002, S. 163–176
- [Streller und Dietmayer 2004] STRELLER, Daniel ; DIETMAYER, Klaus: Object tracking and classification using a multiple hypothesis approach. In: *Intelligent Vehicles Symposium (IV) IEEE (Veranst.)*, 2004, S. 808–812
- [Stüker 2004] STÜKER, D.: *Heterogene Sensordatenfusion zur robusten Objektverfolgung im automobilen Straßenverkehr*, Dissertation, 2004
- [Thrun 2010] THRUN, Sebastian: *What we are driving at.* 2010. – URL <http://googleblog.blogspot.de/2010/10/what-were-driving-at.html>. – Zugriffsdatum: 22.11.2013
- [Thrun u. a. 2005] THRUN, Sebastian ; BURGARD, Wolfram ; FOX, Dieter: *Probabilistic robotics*. Cambridge and Mass : MIT Press, 2005. – ISBN 9780262201629
- [UR:BAN 2013] UR:BAN: *Urbaner Raum: Benutzergerechte Assistenzsysteme und Netzmanagement.* 2013. – URL <http://urban-online.org/de/urban.html>. – Zugriffsdatum: 07.05.2013
- [Urmson u. a. 2008] URMSON, Chris ; ANHALT, Joshua ; BAGNELL, Drew ; BAKER, Christopher ; BITTNER, Robert ; CLARK, MN ; DOLAN, John ; DUGGINS, Dave ; GALATALI, Tugrul ; GEYER, Chris u. a.: Autonomous driving in urban environments: Boss and the urban challenge. In: *Journal of Field Robotics* 25 (2008), Nr. 8, S. 425–466
- [V-Charge 2013] V-CHARGE: *V-Charge: Automated Valet Parking and Charging for e-Mobility Collaborative Project.* 2013. – URL <http://www.v-charge.eu/>. – Zugriffsdatum: 07.05.2013
- [Van Der Merwe 2004] VAN DER MERWE, R.: *Sigma-point Kalman filters for probabilistic inference in dynamic state-space models*, University of Stellenbosch, Dissertation, 2004
- [VDA 2012] VDA: *simTD: Einer der weltweit größten Feldversuche zur Car-to-X Kommunikation in Hessen gestartet.* 2012. – URL <http://www.vda.de/de/meldungen/news/20120807-1.html>. – Zugriffsdatum: 06.05.2013
- [Verhaegen und Van Dooren 1986] VERHAEGEN, M. ; VAN DOOREN, P.: Numerical aspects of different Kalman filter implementations. In: *Automatic Control, IEEE Transactions on* 31 (1986), Nr. 10, S. 907–917
- [Vollmer 2012] VOLLMER, Alfred: *Der Weg zum pilotierten Fahren.* 2012. – URL <http://www.all-electronics.de/texte/anzeigen/47258/Der-Weg-zum-pilotierten-Fahren>. – Zugriffsdatum: 22.11.2013

- [Vu u. a. 2008] VU, T.D. ; BURLET, J. ; AYCARD, O.: Mapping of environment, detection and tracking of moving objects using occupancy grids. In: *Intelligent Vehicles Symposium (IV)* IEEE (Veranst.), 2008, S. 684–689
- [Vu und Aycard 2009] VU, Trung-Dung ; AYCARD, Olivier: Laser-based detection and tracking moving objects using data-driven markov chain monte carlo. In: *International Conference on Robotics and Automation, (ICRA)* IEEE (Veranst.), 2009, S. 3800–3806
- [Vu u. a. 2011] VU, Trung-Dung ; BURLET, Julien ; AYCARD, Olivier: Grid-based localization and local mapping with moving object detection and tracking. In: *Information Fusion* 12 (2011), Nr. 1, S. 58–69
- [Wang u. a. 2007] WANG, C.-C ; THORPE, C. ; THRUN, S. ; HEBERT, M. ; DURRANT-WHYTE, H.: Simultaneous Localization, Mapping and Moving Object Tracking. In: *International Journal of Robotics Research* 26 (2007), Nr. 9, S. 889–916
- [Wang 2004] WANG, Chieh-Chih: *Simultaneous Localization, Mapping and Moving Object Tracking*, Dissertation, 2004
- [Wang u. a. 2003] WANG, Chieh-Chih ; THORPE, Charles ; THRUN, Sebastian: Online Simultaneous Localization and Mapping with Detection and Tracking of Moving Objects: Theory and Results from a Ground Vehicle in Crowded Urban Areas. In: *International Conference on Robotics and Automation, (ICRA)* IEEE (Veranst.), 2003, S. 842–849
- [Welch und Bishop 1995] WELCH, G. ; BISHOP, G.: *An introduction to the Kalman filter*. 1995
- [Winner u. a. 2012] WINNER, H. ; HAKULI, S. ; WOLF, G.: *Handbuch Fahrerassistenzsysteme: Grundlagen, Komponenten und Systeme für aktive Sicherheit und Komfort*. Vieweg+ Teubner Verlag, 2012
- [Winner 2012] WINNER, Hermann: Radarsensorik. In: *Handbuch Fahrerassistenzsysteme*. Springer, 2012, S. 123–171
- [Yu und Wong 2006] YU, Z. ; WONG, H.S.: GCA: A real-time grid-based clustering algorithm for large data set. In: *International Conference on Pattern Recognition, (ICPR)* Bd. 2 IEEE (Veranst.), 2006, S. 740–743
- [Zhao und Thorpe 1998] ZHAO, Liang ; THORPE, Chuck: Qualitative and quantitative car tracking from a range image sequence. In: *Computer Vision and Pattern Recognition, 1998. Proceedings. 1998 IEEE Computer Society Conference on* IEEE (Veranst.), 1998, S. 496–501